

**FERNANDA ISABEL MARQUES ARGOUD**

**CONTRIBUIÇÃO À AUTOMATIZAÇÃO DA  
DETECÇÃO E ANÁLISE DE EVENTOS  
EPILEPTIFORMES EM  
ELETROENCEFALOGRAMA**

**FLORIANÓPOLIS  
2001**

**UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA  
ELÉTRICA**

**CONTRIBUIÇÃO À  
AUTOMATIZAÇÃO DA DETECÇÃO  
E ANÁLISE DE EVENTOS  
EPILEPTIFORMES EM  
ELETROENCEFALOGRAMA**

Tese submetida à  
Universidade Federal de Santa Catarina  
como parte dos requisitos para a  
obtenção do grau de Doutor em Engenharia Elétrica.

**FERNANDA ISABEL MARQUES ARGOUD**

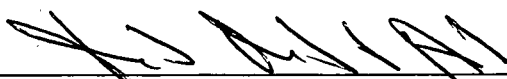
Florianópolis, junho de 2001.



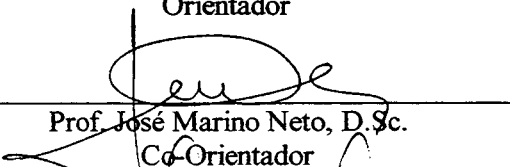
# CONTRIBUIÇÃO À AUTOMATIZAÇÃO DA DETECÇÃO E ANÁLISE DE EVENTOS EPILEPTIFORMES EM ELETROENCEFALOGRAMA

Fernanda Isabel Marques Argoud

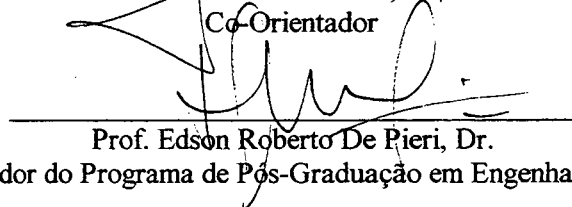
‘Esta Tese foi julgada adequada para obtenção do Título de Doutor em Engenharia Elétrica, Área de Concentração em Engenharia Biomédica, e aprovada em sua forma final pelo Curso de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina.’



Prof. Fernando Mendes de Azevedo, D.Sc.  
Orientador



Prof. José Marino Neto, D.Sc.  
Co-Orientador

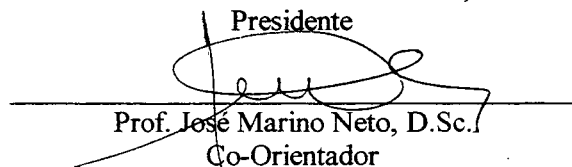


Prof. Edson Roberto De Pieri, Dr.  
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica

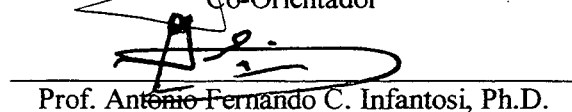
Banca Examinadora:




Prof. Fernando Mendes de Azevedo, D.Sc.  
Presidente



Prof. José Marino Neto, D.Sc.  
Co-Orientador



Prof. Antonio Fernando C. Infantsi, Ph.D.



Prof. Eduardo Tavares Costa, Ph.D.



Prof. Renato Garcia Ojeda, Dr.Eng.



Prof. Raimés Moraes, Ph.D.

Dedico esta conquista ao meu esposo e maior amigo, Patrick  
e à minha família querida: Luci, Luiz, Andréa, Eduardo,  
Rosilene, Padilha, Fátima, Dalva, Lucien, Lara, Zé Paulo, Ana e Daniel...

## **AGRADECIMENTOS**

A Deus, pela vida abençoada que me Proporcionou.

Aos meus queridos Orientadores e Amigos, Prof. Fernando de Azevedo, Prof. José Marino Neto e Prof. Paulo Bittencourt.

À Universidade Federal de Santa Catarina, que moldou tudo o que sou profissionalmente, que foi muito mais que uma Escola e que é motivo de muito orgulho para seus egressos!

Ao Departamento de Engenharia Elétrica da UFSC, por todos os anos de convivência e por todo o apoio e confiança que sempre me foram dados.

A todos os colegas e amigos que passaram pelo Grupo de Pesquisas em Engenharia Biomédica ao longo destes 7 anos; pelo companheirismo, pela amizade, pelas contribuições ao trabalho, por tudo que vocês me ensinaram e por terem sido quase uma família para mim, durante todo este tempo.

À Dra. Vânia Andriani e ao Dr. Bertelli, por toda a ajuda, dicas e apoio ao trabalho.

Ao Wilson e ao Marcos, da CPGEEL, por todo o trabalho que dei a vocês, tantas vezes.

Ao Dr. Jean Gotman, que me recebeu com tanto carinho, atenção e dedicação, meus sinceros agradecimentos.

Resumo da Tese apresentada à UFSC como parte dos requisitos necessários para a obtenção do grau de Doutor em Engenharia Elétrica.

# **CONTRIBUIÇÃO À AUTOMATIZAÇÃO DA DETECÇÃO E ANÁLISE DE EVENTOS EPILEPTIFORMES EM ELETROENCEFALOGRAMAS**

**Fernanda Isabel Marques Argoud**

Junho/2001

Orientador: Prof. Fernando Mendes de Azevedo.

Área de Concentração: Sistemas de Informação.

Palavras-chave: Eletroencefalograma, Transformada *Wavelet*, Redes Neurais Artificiais, Epilepsia, Espículas.

Número de Páginas: 203.

O presente trabalho visa propor uma arquitetura de sistema para processamento de sinais eletroencefalográficos (EEG), que utilize métodos e ferramentas de análise não-linear, tais como Transformada *Wavelet* e Redes Neurais Artificiais (RNAs), com o intuito de fazer-se a detecção e o reconhecimento de descargas epileptiformes do tipo Espícula-Onda (*spikes*), possivelmente presentes no sinal. O sistema baseado em computador proposto (SIDAPE) transforma os sinais de EEG através de Transformada *Wavelet* Rápida (FWT) e a representação resultante serve de entrada para um grupo de Redes Neurais Artificiais, as quais fazem a detecção e a classificação das Descargas Epileptiformes. Para o primeiro estágio do sistema desenvolveu-se uma metodologia no sentido de maximizar o aproveitamento da FWT na identificação automática de espículas do EEG. Assim, determinou-se que, em um conjunto de 47 funções *wavelet kernel* conhecidas, a função *wavelet* Coiflet 1 é a que oferece a maior correlação morfológica com as espículas e, por consequência, maior grau de compactação na decomposição. Utilizou-se também um banco de 4 RNAs do tipo *feedforward*, com treinamento *backpropagation* otimizado, cada uma capaz de identificar um tipo de evento específico no EEG, quais sejam: espículas e ondas agudas, piscadas e ruído muscular. Os resultados foram avaliados para análise de janelas de 15 s e o SIDAPE foi capaz de detectar espículas com 98,4% de especificidade, o que indica segurança quanto a detecções positivas. O sistema também apresentou 96,2% de acertos na classificação; sensibilidade igual a 48,7% e valores preditivo positivo e preditivo negativo de 47,3% e 97,4%, respectivamente.

Abstract of Thesis presented to UFSC as a partial fulfillment of the requirements for the degree of Doctor in Electrical Engineering.

# **CONTRIBUTION TO THE AUTOMATIZATION OF THE DETECTION AND ANALYSIS OF EPILEPTIFORM EVENTS IN ELECTROENCEPHALOGRAM**

**Fernanda Isabel Marques Argoud**

June /2001

Advisor: Prof. Fernando Mendes de Azevedo.

Area of Concentration: Information Systems.

Keywords: Electroencephalogram, Wavelet Transform, Artificial Neural Network, Epilepsy, Spikes

Number of Pages: 203.

The present work suggests a system architecture for Electroencephalographic signal (EEG) processing using nonlinear methods and analysis tools, such as Wavelet Transform and Artificial Neural Networks (ANNs), aiming at the detection and the recognition of Spike-and-Wave epileptiform discharges possibly present in the electrographic sample. The proposed computer-based system (SIDAPE) transforms EEG signals by a Fast Wavelet Transform algorithm (FWT). The resulting wavelets coefficients serve as inputs to a group of Artificial Neural Networks that detect and classify the Epileptiform Discharges. For the system's first stage, it was developed a methodology that maximize the use of FWT in automatic identification of spikes in EEGs. We have noted that in a set of 47 known wavelet functions, the Coiflet 1 correlates better with spikes in morphological appearance and offers the highest compression rate in decomposition. A four feedforward ANNs bank was used, with optimized backpropagation training, each one able to recognize one of the following events in EEG: spikes and sharp waves, blinks and muscle noise. The results were evaluated to analysis of 15 s. windows and showed that SIDAPE could detect spikes with 98,4% of specificity rate, what indicates security as to positive detection. The system also achieved 96.2% of correct classifications; sensibility of 48.7% and positive predictive and negative predictive values of 47.3% and 97.4%, respectively.

# SUMÁRIO

<b>PREFÁCIO .....</b>	<b>1</b>
<b>1. INTRODUÇÃO.....</b>	<b>3</b>
1.1 MOTIVAÇÃO.....	3
1.2 JUSTIFICATIVAS.....	4
1.3 OBJETIVOS .....	6
<b>2. A FISIOLOGIA DO EEG E DAS DESCARGAS EPILEPTIFORMES.....</b>	<b>7</b>
2.1 O ELETROENCEFALOGRAMA .....	7
2.2 ORIGEM DO SINAL DE EEG.....	7
2.3 FISIOLOGIA DO EEG .....	11
2.3.1 <i>Características físicas dos ritmos comuns em EEG.....</i>	<i>11</i>
2.3.2 <i>Características físicas dos ritmos especiais em EEG .....</i>	<i>13</i>
2.3.3 <i>Artefatos presentes no EEG.....</i>	<i>15</i>
2.4 A ELETROENCEFALOGRAFIA .....	18
2.5 INTRODUÇÃO À EPILEPSIA.....	20
2.5.1 <i>Nomenclatura e Terminologia .....</i>	<i>21</i>
2.5.2 <i>Relações entre as epilepsias e o EEG.....</i>	<i>25</i>
<b>3. FERRAMENTAS DO TRABALHO .....</b>	<b>26</b>
3.1 REDES NEURAIS ARTIFICIAIS.....	26
3.1.1 <i>Introdução .....</i>	<i>26</i>
3.1.2 <i>Modelos de Neurônios .....</i>	<i>28</i>
3.1.3 <i>Rede Feedforward com algoritmo de treinamento Backpropagation.....</i>	<i>39</i>
3.2 TRANSFORMADAS DE SINAIS.....	41
3.2.1 <i>As Transformadas.....</i>	<i>41</i>
3.2.2 <i>A Transformada de Fourier de Curto Termo - STFT .....</i>	<i>42</i>
3.2.3 <i>A Transformada Wavelet - WT .....</i>	<i>45</i>
3.2.4 <i>A Transformada Wavelet Discreta - DWT.....</i>	<i>54</i>
3.2.5 <i>A Transformada Wavelet Rápida - FWT.....</i>	<i>59</i>
<b>4. SISTEMAS EXISTENTES.....</b>	<b>61</b>
4.1 ANÁLISE CONVENCIONAL .....	61
4.1.1 <i>Reconhecimento por regras de decisão e modelagem de Espículas.....</i>	<i>61</i>
4.1.2 <i>Sistema de Monitoração remoto com reconhecimento por Modelos de Gotman .....</i>	<i>62</i>
4.1.3 <i>Reconhecimento por Correlação com Função Impulso .....</i>	<i>63</i>
4.2 ANÁLISE ATRAVÉS DE RNAS .....	65
4.2.1 <i>Rede Feedforward para reconhecimento de Espículas e Ondas Agudas (SSWs) com entrada paramétrica .....</i>	<i>66</i>
4.2.2 <i>Rede Feedforward para reconhecimento de DEs, com comparação entre entradas cruas e paramétricas.....</i>	<i>68</i>
4.2.3 <i>Rede LVQ para reconhecimento de DEs .....</i>	<i>71</i>
4.2.4 <i>Redes Neurais para auxílio ao diagnóstico de patologias neurológicas.....</i>	<i>72</i>
4.3 ANÁLISE ATRAVÉS DE TRANSFORMADAS .....	72

4.3.1	<i>Detecção de Paroxismos através da Distribuição de Wigner</i>	73
4.3.2	<i>Detecção de DEs através da WT</i>	73
4.4	ABORDAGENS HÍBRIDAS	75
4.4.1	<i>Detecção de DEs utilizando-se WT e Rede Feedforward</i>	75
4.4.2	<i>Detecção de DEs utilizando-se HT e Rede Feedforward</i>	79
4.5	OUTROS SISTEMAS	82
<b>5.</b>	<b>METODOLOGIA DO TRABALHO</b>	<b>83</b>
5.1	ESCOPO DO PROBLEMA	83
5.2	A BASE DE DADOS	84
5.3	ARQUITETURA GERAL DO SISTEMA	88
5.4	ARQUIVOS DE 15 SEGUNDOS	92
5.5	TRATAMENTO DAS BORDAS	93
5.6	MÓDULO DE TRANSFORMAÇÃO RÁPIDA <i>WAVELET</i>	95
5.6.1	<i>Porque a Transformada Wavelet</i>	95
5.6.2	<i>Aplicação da FWT no trabalho</i>	96
5.6.3	<i>Primeira Abordagem para o Problema de Escolha da Função Wavelet</i>	97
5.6.4	<i>Metodologia empregada para Escolha da Função Wavelet</i>	100
5.6.5	<i>Saídas do Módulo de Transformação</i>	107
5.7	CONDICIONAMENTO DOS SINAIS	111
5.7.1	<i>Normalização dos sinais</i>	111
5.7.2	<i>Cálculo de Média e Desvio-Padrão</i>	111
5.7.3	<i>Épocas de 1 segundo</i>	112
5.7.4	<i>Cálculo dos Máximos e Verificação de Threshold</i>	113
5.8	MÓDULO DE ANÁLISE NEURAL	115
5.8.1	<i>Arquiteturas e Topologias das Redes</i>	118
5.8.2	<i>RNA1 - Rede para Reconhecimento de Espículas</i>	122
5.8.3	<i>RNA2 - Rede para Reconhecimento de Ondas Agudas</i>	127
5.8.4	<i>RNA3 - Rede para Reconhecimento de Ruídos e Artefatos Musculares</i>	128
5.8.5	<i>RNA4 - Rede para Reconhecimento de Piscadas</i>	130
5.9	MÓDULO DE ANÁLISE SIMBÓLICA POR REGRAS DE PRODUÇÃO	132
5.9.1	<i>Regras para Espículas</i>	132
5.9.2	<i>Regra para Ruído</i>	134
5.9.3	<i>Regras para Piscadas (Blinks)</i>	135
5.9.4	<i>Regras Cruzadas</i>	136
5.9.5	<i>Regra Final</i>	137
5.10	ROTINAS DE APRESENTAÇÃO GRÁFICA	138
<b>6.</b>	<b>TESTES E RESULTADOS</b>	<b>139</b>
6.1	TESTES COM O MÓDULO DE TRANSFORMAÇÃO	139
6.2	TESTES COM O MÓDULO DE ANÁLISE NEURAL	141
6.3	PROCEDIMENTO DE TESTE GERAL DO SISTEMA	145
<b>7.</b>	<b>DISCUSSÕES</b>	<b>148</b>
7.1	SOBRE A UTILIZAÇÃO DE VALORES ARBITRÁRIOS OU EMPÍRICOS	148
7.2	SOBRE A ANÁLISE <i>WAVELET</i>	149
7.3	SOBRE A ANÁLISE NEURAL	150

7.4	SOBRE AS REGRAS DE PRODUÇÃO .....	151
7.5	SOBRE OS RESULTADOS.....	151
<b>8.</b>	<b>CONCLUSÕES .....</b>	<b>154</b>
8.1	COM RELAÇÃO AO SISTEMA .....	154
8.2	COM RELAÇÃO ÀS CONTRIBUIÇÕES CIENTÍFICAS .....	157
<b>9.</b>	<b>SUGESTÕES PARA TRABALHOS FUTUROS .....</b>	<b>158</b>
<b>ANEXO A - ALGORITMO FWT (<i>FAST WAVELET TRANSFORM</i> - TRANSFORMADA <i>WAVELET</i> RÁPIDA) .....</b>		<b>160</b>
<b>ANEXO B -<i>SOFTWARES</i> DE ANÁLISE <i>WAVELET</i> DE DOMÍNIO PÚBLICO OU <i>SHAREWARES</i> .....</b>		<b>164</b>
<b>ANEXO C – DETALHES ACERCA DOS REGISTROS DE EEG COMPONENTES DA BASE DE DADOS DE TREINAMENTO E TESTES DO SIDAPE .....</b>		<b>165</b>
<b>GLOSSÁRIO .....</b>		<b>169</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>		<b>172</b>



## LISTA DE FIGURAS

Figura 1.1— Trecho de EEG com Complexo Espícula-Onda ressaltado (canal do centro, à esquerda). ....	4
Figura 2.1: Representação esquemática da morfologia e histologia dos elementos neuronais e gliais. (Modificado de <i>Electroencephalography</i> [128]). ....	8
Figura 2.2: O neurônio biológico e a sinapse. ....	8
Figura 2.3: Alteração no Potencial de Membrana (PM) de células gliais induzida pelo aumento de concentração de K <sup>+</sup> extracelular. A) Potássio é aplicado extracelularmente à célula glia. B) A concentração de potássio aumenta devido à uma ativação da vizinhança neuronal. (Modificado de <i>Electroencephalography</i> [128] ). ....	9
Figura 2.4: Princípio de geração dos sinais. Eletrodos: E <sup>1</sup> e E <sup>2</sup> -registram os potenciais intracelulares das fibras aferentes; E <sup>3</sup> e E <sup>4</sup> - potenciais de membrana (PM) dos elementos dendríticos; E <sup>5</sup> - potencial de campo. Grupos síncronos de potenciais de ação nas fibras aferentes geram sinais EPSPs, resultantes da integração destes potenciais, nas áreas dendríticas e correspondentes potenciais de campo nos registros EEG e DC/EEG. (Modificado de <i>Electroencephalography</i> [128] ). ....	10
Figura 2.5: Exemplos de atividade (a) delta, (b) teta, (c) alfa e (d) beta. (e) Bloqueio do ritmo alfa através de abertura dos olhos. (f) Marcador de 1 segundo de tempo e calibração. (Modificado de <i>EEG Technology</i> [34]). ....	12
Figura 2.6: Os estágios do sono no EEG (1 a 4 ou A a D e E). (Modificado de Catálogo da Produtos Roche, Ltda, Londres). ....	13
Figura 2.7: Exemplos de formas de onda específicos (eletrodo de referência no queixo). (a)Complexos-K; (b) Onda Lambda; (c)Ritmo mu; (d)Espículas; (e)Ondas Agudas; (f)Atividade Espícula-Onda repetitiva; (g)Fusos do Sono; (h)Ondas Agudas do Vértex; (i)Descargas Poliespícula. (Modificado de <i>EEG</i> <i>Technology</i> [34]). ....	14
Figura 2.8: Artefatos provenientes de eletrodos e de cabos condutores de entrada; (a) devido a movimento dos eletrodos; (b) devido a contato pele-eletrodo imperfeito; (c) devido à contaminação por contato entre eletrodo e cliques; e (d) devido à contaminação por contato entre plugue de entrada e soquete. (Modificado de <i>EEG Technology</i> [34]). ....	16
Figura 2.9: Deflexões típicas produzidas por movimentos verticais e laterais dos olhos em canais dispostos nas regiões frontais e temporais (Modificado de <i>EEG Technology</i> [34]). ....	17
Figura 2.10: (a) Exemplos de atividade muscular registrados a partir de eletrodos no escalpo. (b) O efeito da atenuação de alta-freqüência (filtragem passa-baixas com atenuação das componentes de freqüência superiores a 25 Hz) na atividade muscular mostrada no traçado superior. (Modificado de <i>EEG</i> <i>Technology</i> [34]). ....	17
Figura 2.11: Artefatos devidos à atividade cardíaca. (a) Artefatos de pulsação em um mesmo indivíduo. (b) Artefatos de ECG em um mesmo indivíduo. (Modificado de <i>EEG Technology</i> [34]). ....	17
Figura 2.12: O primeiro registro eletroencefalográfico realizado em humanos, por Berger. (Original de Berger, 1929 [14]. Modificado de <i>Electroencephalography</i> , 1993 [97]). ....	18
Figura 2.13: Disposição de eletrodos no escalpo e nomenclatura do sistema 10-20 Internacional letra-número: Números ímpares à esquerda, pares, à direita e Z ou 'zero', na linha mediana. (a) Oito; (b) Treze e (c) Dezesseis eletrodos. (Modificado de <i>Electroencephalography</i> , 1993 [97]). ....	18
Figura 2.14: (a) Método bipolar de ligação de eletrodos (e <sub>i</sub> ) no escalpo. Conexões de entrada do amplificador de EEG representadas por V <sub>i</sub> . (b) Método unipolar ou de eletrodo comum (e <sub>r</sub> ). (c) Sistema de Referência Média Comum (e <sub>ar</sub> ). (Modificado de <i>EEG Technology</i> , 1974 [34]) ....	19
Figura 3.1: Modelo de neurônio artificial de McCulloch e Pitts (Modificado de Barreto [12]). ....	29
Figura 3.2: Neurônio Artificial.( Extraído de De Azevedo, 1997 [39]) ....	31
Figura 3.3: Funções de ativação unipolares. ( Extraído de De Azevedo, 1997 [39]) ....	34
Figura 3.4: Funções de ativação bipolares. ( Extraído de De Azevedo, 1997 [39]) ....	34
Figura 3.5: Função de ativação sigmóide “hard limit”. ....	35
Figura 3.6: Arquitetura de Rede Neural Artificial - a <i>Feedforward</i> . ( Extraído de De Azevedo, 1997 [39]) ....	37
Figura 3.7: Rede Neural Direta com 1 camada interna mais as camadas de entrada e de saída, completamente conectada. Cada neurônio, nas camadas interna e de saída da rede, é composto de um somatório ponderado <i>net</i> das entradas dos neurônios da camada anterior (e do <i>bias</i> , se houver) seguido de uma função de transição de estados $\phi$ e de uma função de saída $\lambda$ . ....	40
Figura 3.8: Dois sinais diferentes no tempo, mas com iguais composições em freqüência e com eventos transientes ocorrendo em momentos diferentes, geram espectros de magnitude de freqüência idênticos. ....	42

Figura 3.9: Sinal não-estacionário acima e sinal estacionário abaixo: diferentes no tempo, mas com iguais composições em frequência geram espectros de magnitudes de frequência idênticos.....	43
Figura 3.10: Representação tempo-frequência de um sinal que consiste de três senoidais consecutivas de frequências $f_1, f_2, f_3$ , respectivamente e um transiente ocorrido no instante $t_3$ . O sinal correspondente no domínio do tempo, $x(t)$ , é mostrado abaixo. $T_x(t, f)$ é mostrado no alto e o espectro de Fourier é mostrado horizontalmente, à esquerda. (Modificado de <i>The Transforms and Applications Handbook</i> [121]). ....	44
Figura 3.11: Cobertura do espaço tempo-frequência da STFT, onde $\Delta\omega$ e $\Delta t$ são fixos para todo o plano - Espectrograma (Modificado de <i>The Transforms and Applications Handbook</i> [121]). ....	45
Figura 3.12: Representação dos filtros passa-banda (transformadas de Fourier das funções janela de tempo) da STFT e da WT no domínio da frequência.....	46
Figura 3.13: Algumas <i>wavelets</i> simétricas em várias escalas e locações. Os pares $(a, \tau)$ que marcam cada forma de onda denotam a escala e a translação, respectivamente. A figura (A) mostra o domínio do tempo, e (B), as <i>wavelets</i> representadas no domínio da frequência. (Modificado de [44]) .....	48
Figura 3.14: Funções Gaussianas em: (a) Base de Gabor e (b) Base <i>Wavelet</i> de Morlet, com $a = 2^m$ e $\tau = ns$ , para diferentes $m$ . Em (c), a representação tempo-frequência da Transformada de Gabor e tempo-escala da WT para uma função degrau $f(t)$ . (Modificado de <i>The Transforms and Applications Handbook</i> [121]). ....	50
Figura 3.15: <i>Wavelet</i> “Chapéu-Mexicano” $\psi(t)$ e sua Transformada de Fourier $\omega$ . (Modificado de <i>The Transforms and Applications Handbook</i> [121]). ....	50
Figura 3.16: <i>Wavelet</i> básica de Haar $\psi(t)$ e sua Transformada de Fourier $\omega$ . (Modificado de <i>The Transforms and Applications Handbook</i> [121]). ....	51
Figura 3.17: Funções de escala e <i>wavelets</i> de Daubechies. (Modificado de <i>Réalisation d'une bibliothèque C de fonctions ondelettes</i> [20]). ....	52
Figura 3.18: Exemplos de funções <i>wavelet</i> disponíveis no aplicativo Matlab 5.0®. Funções de Haar, Daubechies 2, Symlet 4, Coiflet 1, Coiflet 5 e Biortogonal 2.4 (nesta, a fração corresponde às ordens das funções de decomposição e de reconstrução). ....	53
Figura 3.19: Representação tempo-escala na Transformada <i>Wavelet</i> Contínua.....	54
Figura 3.20: Transformada <i>Wavelet</i> Contínua de sinal de EEG, no alto. Notar que a presença de espículas nos intervalos [200,400] e [600,800] gerou valores altos (mais escuros) de potências dos coeficientes no escalograma e para valores de escala mais baixos. ....	55
Figura 3.21: Representação tempo-frequência de um sinal que consiste de três senoidais consecutivas de frequências fundamentais $f_1, f_2, f_3$ , respectivamente e de um transiente em $t_3$ . O sinal correspondente no domínio do tempo é mostrado no alto, e o respectivo escalograma 3D é simulado abaixo. Notar que a ocorrência do transiente no intervalo $[t_3, t_4]$ gerou uma célula no escalograma de baixa escala e com largura de banda maior, bem localizada no tempo. Já as outras células correspondem a componentes com frequências bem definidas e portanto, estão bem localizadas em frequência. ....	55
Figura 3.22: Representação tempo-escala na Transformada <i>Wavelet</i> Discreta.....	57
Figura 3.23: Ilustração comparativa entre escalogramas referentes à DWT e à CWT de um mesmo sinal, representado no alto (Tutorial do Matlab 5.0®) .....	57
Figura 3.24: À esquerda – (a) Funções de escala $\phi(t)$ em níveis decrescentes de resolução ( $j = 0, -1, -2, \dots, -6$ ). (b) Transformadas de Fourier correspondentes às funções de escala. À direita: Funções <i>wavelet</i> $\psi(t)$ em níveis decrescentes de resolução ( $j = 0, -1, -2, \dots, -6$ ). (b) Transformadas de Fourier correspondentes às funções <i>wavelet</i> .....	58
Figura 3.25: Aplicação de Filtros Multiresolução em Quadratura a um sinal $f(t)$ (também chamado de $c_0(t)$ ). Os filtros $G(t)$ extraem os detalhes $d_i(t)$ , ou $cd_i$ , do sinal. Os filtros $H(t)$ extraem as aproximações do sinal (características “coarser”) $c_i(t)$ , ou $ca_i$ , em níveis $i$ cada vez menores de refinamento, com aumento da escala. ....	60
Figura 3.26: Acima e à esquerda – sinal original, posteriormente decomposto em 3 níveis através de FWT no MATLAB®. À esquerda e de baixo para cima – componente de detalhe 1 (cd1), componente de detalhe 2 (cd2), componente de detalhe 3 (cd3) e aproximação 3 (ca3). À direita e de baixo para cima: sinal reconstituído a partir de cd1, sinal reconstituído a partir de cd2, sinal reconstituído a partir de cd3 e sinal reconstituído a partir da ca3. Notar que, à medida que aumenta o valor da escala diminuem os valores das frequências envolvidas nas componentes. ....	60
Figura 4.1: Características de frequência e fase do sistema de detecção de espículas. (a) Diferenciador. (b) Diferenciador + TH. (Modificado de <i>Portable Analyser for Real-Time Detection of the Epileptic PreCursor</i> [130]) .....	63

Figura 4.2: Estágios do algoritmo de detecção de espículas. (a) Padrão Complexo Espícula-Onda, CEO, apresentado à entrada. (b) Saída após Operador Diferencial. (c) Saída após Operadores Diferencial + TH. (Modificado de <i>Portable Analyser for Real-Time Detection of the Epileptic Pre-Cursor</i> [130]).	63
Figura 4.3: Operação do detector de espículas completo. (a) CEO apresentado à entrada. (b) Saída do detector de Espículas. (c) Saída do filtro cúbico. (Modificado de <i>Portable Analyser for Real-Time Detection of the Epileptic Pre-Cursor</i> [130]).	64
Figura 4.4: (a) Sinal. (b) Detecção de um CEO, para os níveis de resolução $j = 3$ e $j = 5$ ; intervalo de tempo de 2 s. (Modificado de <i>Detection of Epileptic Events in Electroencephalograms Using Wavelet Analysis</i> [9]).	74
Figura 4.5: Representação multiescala da TW de (a) um CEO, e de (b) uma atividade de EMG, utilizando a <i>Wavelet</i> Daub-20. A figura mostra as 6 escalas superiores. As duas barras verticais nos sinais do alto abrangem 80 ms. Os oito coeficientes tomados de cada escala são indicados pelas setas. (Modificado de <i>Wavelet Preprocessing for Automated Neural Network Detection of EEG Spikes</i> [77]).	77
Figura 4.6: 1 - Análise do canal C4 baseada em TH1. As linhas verticais indicam o intervalo de análise (60 ms) para a segunda espícula presente no sinal. (A) Sinal no canal C4 - amplitudes - $S$ designa o <i>threshold</i> para uma detecção de espícula (empiricamente estimado), (B) Série temporal PCG; (C) Série temporal PI de (A); (D) Série temporal FI de (A). 2 - Sequência de mapas PI durante o intervalo de ocorrência da segunda espícula, no segmento mostrado em 1(A). Cada mapa está normalizado entre os valores mínimo e máximo da amostra. (Modificado de <i>Analysis and classification of interictal spike discharges in benign partial epilepsy of childhood on the basis of the Hilbert transformation</i> [68]).	81
Figura 5.1: Diagrama de Contexto do Sistema SIDAPE. O sistema recebe dados contínuos de EEG digitalizados, organiza-os em segmentos de 15 segundos de registro e a partir destes gera arquivos contendo as informações de detecção. Os arquivos de 15 segundos e de detecção são posteriormente utilizados para apresentação gráfica dos resultados ao revisor.	83
Figura 5.2: Um tipo de montagem zigomática-temporal bipolar utilizando 25 eletrodos arranjados em 32 canais (derivações bipolares marcadas com números ao lado das flechas). Os números ao lado das setas identificam as derivações bipolares. Os eletrodos Zg1 e Zg2 (ou Zy1 e Zy2) são posicionados nos maxilares.	86
Figura 5.3: Diagramas de Módulos do SIDAPE.	89
Figura 5.4: Separação dos canais dos registros de EEG realizada na entrada do SIDAPE.	89
Figura 5.5: Esquemas de tratamento de bordas, transformação <i>Wavelet</i> , reconstrução, condicionamento e separação de épocas de 1 segundo para cada canal analisado. Ao final, o sistema verifica se o <i>threshold</i> foi ultrapassado e envia a época, caso afirmativo, para a etapa de Análise Neural.	91
Figura 5.6: Caso o valor de máximo na época de 1 segundo tenha ultrapassado o <i>threshold</i> (Média + 7.5 Desvios-padrão), este será submetido a um grupo de quatro Redes Neurais Artificiais, cada uma treinada para reconhecer um tipo específico de evento. As saídas das redes serão analisadas por um Base de Regras, com o objetivo de fornecer uma saída sobre a possibilidade de ocorrência de uma espícula na época.	92
Figura 5.7: Acima: Sinal de EEG com descontinuidades abruptas nos pontos de bordas (índices 1 e 1500). Abaixo: Sinal transformado com distorções (marcadas com elipses) nas bordas, devido às descontinuidades no tempo.	94
Figura 5.8: (a) Registro original de 32 canais durante 15 segundos, no alto. (b) Registro onde todos os canais foram transformados utilizando-se a função <i>Wavelet</i> Coiflet 1 e reconstruídos apenas a partir da componente de detalhe 1. Notar como o ruído nos canais 4 e 5 foi evidenciado. (c) Registro onde todos os canais foram transformados utilizando-se a função <i>Wavelet</i> Coiflet 1 e reconstruídos apenas a partir da componente de detalhe 2. Notar como as espículas (principalmente nos 7º e 8º segundos de registro) foram ressaltadas.	98
Figura 5.9: Exemplo de aplicação do algoritmo “Optimal Matched <i>Wavelet</i> ”, de Chapa e Rao [26]. (a) Padrão Espícula-Onda, claramente positivo, com altas frequências na região das espículas e com pico de grande amplitude; (b) Função <i>Wavelet</i> derivada através do algoritmo, com oscilações suaves, amplitude média nula e sem projeção do pico referente à espícula.	99
Figura 5.10: Acima: trecho de sinal de EEG com Complexo Espícula-Onda ao centro. Abaixo à esquerda: função senoidal utilizada pela FFT para decomposição. Abaixo à direita: função <i>Wavelet</i> Symlet de ordem 4, claramente mais próxima morfológicamente do padrão Espicular que a senóide.	100
Figura 5.11: A tarefa de escolher a função <i>Wavelet</i> mais adequada para detecção de espículas pode ser interpretada, no domínio da frequência, como encontrar aquela função cuja banda passante amplificaria mais as componentes de frequência das espículas e ondas agudas.	101

Figura 5.12: Distribuições de frequências do registro de EEG “jok_15.mat” (32 canais), com média zero e envelope próximo à Distribuição Normal .....	102
Figura 5.13: Ordenadas - amplitudes em microVolts. Abscissas – tempo em segundos. Transformação FWT de um sinal <i>s</i> (no alto) em 6 níveis de decomposição e posterior reconstituição a partir das componentes. As espículas-onda (segundos 3 e 6) foram evidenciadas, em relação aos demais eventos existentes no registro, nas componentes de detalhe 2 e 3 (maiores variações de amplitude em relação às amplitudes médias). As componentes a partir do nível de decomposição 5 trazem pouca informação relevante acerca do sinal de EEG e o sinal reconstruído a partir da componente de detalhe 1 contém informação clara sobre o ruído no início do sinal <i>s</i> . .....	104
Figura 5.14: Diagrama de Blocos do Módulo de Transformação do SIDAPE. ....	108
Figura 5.15: Trecho de sinal de 1 segundo de EEG, com espícula à direita (acima) e os sinais reconstruídos a partir dos vetores de coeficientes detalhe 2 e detalhe 3 (abaixo). Notar como o sinal obtido a partir do detalhe 2 praticamente mantém apenas a espícula, em relação ao resto dos eventos. Já o sinal obtido do detalhe 3 apresenta-se mais “serrilhado”. ....	108
Figura 5.16: Acima: sinal com espícula-onda a partir dos 400 ms do segmento. Abaixo: sinais reconstruídos a partir dos vetores de detalhe 2 e 3. O sinal obtido do detalhe 3 teve máxima amplitude absoluta exatamente no ponto correspondente ao pico da espícula, porém apresentou excessivo <i>ripple</i> , o que dificultaria o trabalho da rede de reconhecimento e diferenciação. Ou seja, o sinal obtido do detalhe 2 localizou melhor a espícula.....	109
Figura 5.17: Acima: Sinal de EEG com onda aguda, ao centro. Abaixo: apenas o sinal derivado da componente de detalhe 3 foi capaz de ressaltar a onda <i>sharp</i> .....	109
Figura 5.18: De cima para baixo - Investigação os conteúdos de frequência, via FFT, do sinal <i>s</i> da Figura 5.13 e dos sinais reconstruídos a partir das componentes de detalhe 1, detalhe 2 e detalhe 3. ....	110
Figura 5.19: O SIDAPE toma os sinais reconstruídos a partir da FWT e calcula suas médias e desvios-padrões. Após isto, o ponto máximo em cada época é calculado e estimado em número de desvios além da média. As linhas cinza marcam o <i>threshold</i> para amplitudes de 7,5 desvios acima de cada média. Notar que no sinal reconstruído a partir do detalhe 2, apenas o pico (com amplitude igual à média mais 9 desvios-padrão) referente a uma espícula do sinal original (circundada no alto) superou o <i>threshold</i> . ....	112
Figura 5.20: Diagrama de Blocos simplificado do Módulo de Condicionamento dos sinais.....	114
Figura 5.21: Acima – Padrões ambíguos no EEG (segundos 5 e 13) com morfologias epilépticas devidos a ritmo alfa. Abaixo – saída da FWT, indicando que nenhum evento ultrapassou o <i>threshold</i> de 7,5 desvios. O sinal não foi, então, enviado ao Módulo de Análise Neural.....	114
Figura 5.22: Acima – Padrões epileptiformes ambíguos no EEG (segundos 6-8 e 11) , mas desta vez com espícula real no segundo 11 (retângulo tracejado). Abaixo – saída da FWT, indicando que apenas o evento espícula ultrapassou o <i>threshold</i> , com quase 10 desvios além da média. A época do 11º. segundo seria enviada ao Módulo de Análise Neural. ....	114
Figura 5.23: Acima – padrões epileptiformes referentes a ritmo alfa (sempre mais intenso nas regiões occipitais). Abaixo – Crise Epiléptica Eletroencefalográfica, neste caso mais intensa na região posterior direita do córtex. Notar também os eventos piscadas rápidas, de grandes amplitudes, no instante 13:35:49. Trechos recortados de telas de apresentação do SIDAPE. ....	115
Figura 5.24: Acima – padrões epileptiformes referentes a movimento ocular (presentes apenas nos canais frontais), nos canais Zy1-Zy2 e Eogl-Eogr. Abaixo – Espículas “Ordinárias” (pouco evidentes/claras) espalhadas pelo hemisfério direito do córtex. Trechos recortados de telas de apresentação do SIDAPE. ....	116
Figura 5.25: Acima – padrões epileptiformes referentes a artefatos (provavelmente artefatos de paciente e de eletrodo). O padrão à esquerda manifestou-se, inclusive, em vários canais, já o à direita é um paroxismo isolado, e portanto, mais fácil de se refutar. Abaixo – Espículas rápidas, semelhantes a ruídos musculares, principalmente no instante de registro 22:33:13. Trechos recortados de telas de apresentação do SIDAPE. ....	117
Figura 5.26: Acima – padrões epileptiformes referentes a piscadas (manifestam-se apenas nos canais frontais e possuem morfologia de “v”). Abaixo, no penúltimo segundo de registro do trecho – Ondas Agudas (ou “ <i>sharp</i> ”) epileptogênicas e com morfologia de “v”. Trechos recortados de telas de apresentação do SIDAPE. ....	117
Figura 5.27: Curvas de Treinamento para a rede definitiva RNA1 do sistema, de reconhecimento de espículas. Acima, a evolução do Erro Quadrático Global, por ciclo de treinamento. A rede foi treinada em 295 mil ciclos, aproximadamente, até atingir-se o Erro Global Máximo de 0,01. Abaixo, a variação da taxa de aprendizado, ao longo deste treinamento: quando o erro mantinha-se em decréscimo, a taxa de	

aprendizado era aumentada e quando o erro aumentava de um ciclo para o outro a taxa de aprendizado tinha seu valor diminuído.....	119
Figura 5.28: Topologia das redes neurais do SIDAPE. Rede direta, completamente conectada entre camadas e treinada com algoritmo supervisionado <i>Backpropagation</i> . ....	121
Figura 5.29: Exemplos de épocas de 1 segundo utilizados no treinamento da primeira rede RNA1. No alto: à esquerda, sinal <i>vad1_1260</i> [5], com espícula de período positivo entre os pontos 60 e 80. No alto: à direita, sinal <i>lap_15</i> [14], absolutamente normal. Abaixo, ao centro: sinal <i>wam_15</i> [25], normal com onda lenta.....	124
Figura 5.30: Exemplos de trechos de 1 s utilizados no teste da primeira rede RNA1 e corretamente classificados. No alto: à esquerda, sinal <i>wam_720</i> [1], com espícula de projeção positiva entre os pontos 40 e 60. No alto: à direita, sinal <i>jok_585</i> [3], com ocorrência de duas espículas-onda consecutivas. Abaixo, à esquerda: sinal <i>sr2_1080</i> [4], com complexo biespícula-onda ao centro. Abaixo, à direita: sinal <i>lap_240</i> [10], normal com pequena atividade alfa no início.....	125
Figura 5.31: Padrão classificado erroneamente pela rede. Apesar de ser uma espícula óbvia, o vetor reconstruído a partir dos detalhes 2 Coiflet 1 forneceu um pico referente à espícula com amplitude muito baixa, além da média. Mesmo o vetor reconstruído a partir dos detalhes 3 apenas forneceu um pico de 6 desvios em relação à média. ....	126
Figura 5.32: Exemplos de arquivos utilizados para o treinamento da rede RNA2. As ondas agudas estão marcadas com elipses e os vetores abaixo mostram os sinais reconstruídos a partir dos vetores de coeficientes detalhe 3 da FWT Coiflet 1. Todos os arquivos resultaram em picos de amplitude discrepantes em relação à média para o detalhe 3 e em picos de amplitudes consideravelmente menores para o detalhe 2.....	128
Figura 5.33: Curvas de treinamento da rede utilizada para reconhecimento de ruídos e artefatos no SIDAPE. ....	129
Figura 5.34: Dois exemplos de sinais utilizados no treinamento da rede de reconhecimento de ruídos RNA3. À esquerda – no alto vê-se o sinal de EEG com ruído muscular e seu correspondente vetor reconstruído a partir do detalhe 3, ao centro. Notar que o pico do sinal reconstruído ultrapassou o limiar tal como o faria uma espícula. Para evitar o problema de uma falsa detecção positiva a rede RNA3 foi treinada com o sinal na posição inferior, ou seja, o vetor reconstruído a partir dos coeficientes de detalhe 1, os quais guardam a informação da ocorrência de altas frequências no sinal original e além da banda de frequências das espículas e ondas agudas. À direita – a mesma situação do sinal anterior, só que desta vez foi o vetor obtido a partir do detalhe 2 que “detectou” a falsa espícula. À direita e abaixo se vê o vetor utilizado para treinamento da RNA3. ....	129
Figura 5.35: Curvas de treinamento da rede destinada ao reconhecimento de piscadas e movimentos oculares no SIDAPE. ....	131
Figura 5.36: Dois exemplos de sinais utilizados no treinamento da rede RNA4 de reconhecimento de piscadas e seus vetores reconstruídos a partir do detalhe 3 abaixo. ....	131
Figura 5.37: Ruídos musculares presentes no EEG (canais frontais-temporais esquerdos, principalmente, mas também nos canais T10-P10 e P10-O2, a partir do 11º. segundo do registro) que invalidam a análise de espículas (apesar de aparentemente existirem espículas no 2º. segundo do registro) e que possuem amplitudes muito elevadas, acima da faixa típica para sinais eletroencefalográficos. ....	134
Figura 5.38: Sinal de EEG com presença de eventos piscadas mais intensos nos canais Eogl-Eogr, Fp1-F7, Fp2-F8, Fp1-F3, Fp2-F4, Fp1-F9 e Fp2-F10, ao centro da tela, no instante 13:30:05. ....	135
Figura 5.39: Exemplo de tela do SIDAPE de apresentação gráfica dos sinais e dos resultados de detecção de espículas (marcadas com um fundo mais escuro), em até 32 canais, na tela do computador.....	138

## LISTA DE TABELAS

Tabela 2.1: CLASSIFICAÇÃO DAS CRISES EPILÉPTICAS .....	23
Tabela 2.2: CLASSIFICAÇÃO INTERNACIONAL DAS EPILEPSIAS E SÍNDROMES EPILÉPTICAS E CONDIÇÕES RELACIONADAS.....	23
Tabela 2.3: PRINCIPAIS CARACTERÍSTICAS CLÍNICAS DAS CRISES COM RELAÇÃO À LOCALIZAÇÃO NOS LOBOS .....	24
Tabela 4.1: Comparação entre RNAs que utilizam dados crus e parametrizados como entrada. As classes “definitivamente epileptiforme” e “possivelmente epileptiforme” estão agrupadas em uma só classe. Medidas percentuais. ....	70
Tabela 4.2: Janelas e Correspondentes Comprimentos de Onda. (Extraída de <i>Wavelet Preprocessing for Automated Neural Network Detection of EEG Spikes</i> [77]).....	76
Tabela 4.3: Valores Percentuais de Melhores Performances para RNAs. (Extraída de <i>Wavelet Preprocessing for Automated Neural Network Detection of EEG Spikes</i> [77]). ....	79
Tabela 5.1: Resultados finais da Análise .....	106
Tabela 5.2: Conjunto de Treinamento da primeira rede RNA1 implementada. Foram utilizadas 29 épocas de 1 segundo de duração. O nome do paciente que forneceu a época e a janela de 15 segundos/32 canais onde esta foi selecionada são dados pela coluna <i>Nome do Arquivo</i> . Dentre os 32 ou 24 canais da janela de 15 segundos, retirou-se a época do canal dado pela coluna <i>Número do Canal</i> , segundo a montagem zigomática-temporal e do “segundo” dado pelo intervalo de amostragem [ <i>Ponto inicial na janela, Ponto inicial na janela+99</i> ]. A coluna <i>Tipo de Sinal</i> fornece o tipo de evento constante na época. A coluna <i>Valor Target</i> indica se este evento é epileptogênico (próximo ou igual a 1), ou não (próximo ou igual a 0).....	122
Tabela 5.3: Conjunto de Teste da primeira rede RNA1 implementada. Apenas o arquivo [7] não forneceu uma saída próxima do valor 1 esperado.....	123
Tabela 5.4: Dados sobre os conteúdos e os tamanhos dos Conjuntos de Treinamento das Redes Neurais Artificiais do SIDAPE. ....	132
Tabela 6.1: Resultados dos Testes com o Módulo de Transformação para os valores de <i>threshold</i> de 7,0 e 7,5 desvios-padrão além das amplitudes médias calculadas para os registros. O <i>threshold</i> de 7,5 apresentou especificidade ligeiramente maior, mas sensibilidade consideravelmente menor que o <i>threshold</i> de 7,0. A taxa de acerto média foi de aproximadamente 96%. As colunas referem-se aos acertos e erros do Módulo, em relação às detecções, da seguinte forma: VP- verdadeiro positivo; FP- falso positivo; VN- verdadeiro negativo; FN- falso negativo.....	140
Tabela 6.2: Resultados dos Testes com o Módulo de Análise Neural para as redes RNA1 (detecção de espículas) e RNA2 (detecção de ondas rápidas agudas). A rede RNA1 foi mais seletiva (92,3% de especificidade) e a rede RNA2 apresentou um valor de sensibilidade mais satisfatório (73,1%), porém não foi tão seletiva quanto aos eventos detectados como a RNA1. As taxas de acerto médio foram de 88,6% para a RNA1 e de 77,3% para a RNA3. ....	142
Tabela 6.3: Resultados dos Testes com o Módulo de Análise Neural para as redes RNA3 (detecção de artefatos e ruídos) e RNA4 (detecção de piscadas e movimentos oculares). ....	143
Tabela 6.4: Resultados dos Testes com o Módulo de Análise Neural para o conjunto formado pelas redes RNA1 e RNA2 – detecção de espículas e ondas agudas. Os valores de sensibilidade e especificidade assumiram valores intermediários aos assumidos individualmente pelas duas redes.....	144
Tabela 6.5: Resultados dos testes realizados com o sistema SIDAPE em 126.000 trechos (com 1 segundo cada, de duração) de registros de EEG de 9 pacientes.....	147

## LISTA DE ABREVIATURAS

ANN	– Rede Neural Artificial
APD	– Alterações Paroxísticas Despolarizantes
CBR	– Raciocínio Baseado em Casos
CEO	– Complexo Espícula-Onda
CPC	– Crise Parcial Complexa
CPE	– Complexo Poliespícula
CPEO	– Complexo Poliespícula-Onda
CPS	– Crise Parcial Simples
CTCG	– Crise Tônico-Clônica Generalizada
CWT	– Transformada <i>Wavelet</i> Contínua
DC	– Corrente Contínua
DE ou ED	– Descarga Epileptiforme
DEg	– Descarga Epileptogênica
DWT	– Transformada <i>Wavelet</i> Discreta
ECoG	– Eletrocorticograma
EEG	– Eletroencefalograma (de superfície)
$E_i$	– Eletrodo de índice $i$
EMG	– Eletromiograma
EOG	– Eletroculograma
EP	– Potenciais Evocados
EPSP	– Potencial Pós-Sináptico Excitatório
FFT	– Transformada de Fourier Rápida
FPA	– Filtro Passa-Altas
FPB	– Filtro Passa-Baixas

FPF – Filtro Passa-Faixa ou Passa-Banda

FT – Transformada de Fourier

FWT – Transformada *Wavelet* Rápida

GPEB – Grupo de Pesquisas em Engenharia Biomédica

HT – Transformada de Hilbert

IA ou AI – Inteligência Artificial

IPSP – Potencial Pós-Sináptico Inibitório

$K^+$  – íon de Potássio

LVQ – Vetor de Quantização Linear

MAK – Mapa Auto-Organizável de Kohonen

MNI – Montreal Neurological Institute

MLP – rede neural Perceptron Multicamada

NA – neurônio artificial

PM – Potencial de Membrana

PNN – Rede Neural Probabilística

RBR – Raciocínio baseado em Regras

REM – *Rapid Eye Movement*, fase do sono

RNA – Rede Neural Artificial

SIDAPE – Sistema de Detecção Automática de Paroxismos

SN – Sistema Nervoso

SNC – Sistema Nervoso Central

STFT – Transformada de Fourier de Curto Termo

UFSC – Universidade Federal de Santa Catarina

WT ou TW – Transformada *Wavelet*



## PREFÁCIO

Desde os primórdios das civilizações, o ser humano vem se dispondo a analisar e tentar compreender fenômenos naturais, utilizando-se dos mais variados tipos de métodos e técnicas posto que, via de regra, estes fenômenos não são eventos triviais e tampouco facilmente compreensíveis. Dentre os fenômenos que mais intrigam o homem encontram-se alguns que apresentam uma característica muito peculiar: são originados a partir do próprio funcionamento do corpo humano e, no entanto, não são menos complexos por esta razão. De fato, alguns fenômenos relacionados ao funcionamento da máquina, que é o corpo humano, representam alguns dos mistérios mais inescrutáveis a serem desvendados pela raça humana.

O eletroencefalograma (EEG) é um destes mistérios ainda não esgotados pelos cientistas das mais variadas áreas. O interessante é que este sinal refere-se à parte importante do controle intrínseco de processos do corpo humano. Grande parte dos eventos e ações realizados pelo corpo humano é originada a partir de um impulso elétrico cerebral, seja ele de que ordem for, e de uma maneira tão complexa que por vezes escapa à compreensão humana.

A proposta do presente trabalho é contribuir para o refinamento de métodos utilizados na elucidação de algumas relações entre o sinal de EEG e o comportamento humano decorrente, mais especificamente o comportamento epiléptico, utilizando-se técnicas computacionais modernas. Uma descrição sucinta da organização e dos conteúdos dos capítulos deste trabalho segue nos parágrafos abaixo.

O Capítulo 1 trata das motivações, justificativas e objetivos do trabalho, como introdução para os capítulos subseqüentes.

No Capítulo 2, descreve-se uma breve fundamentação teórica acerca da fisiologia do sinal de EEG em si. Serão esboçadas as principais características deste sinal, como e onde é gerado, como pode ser utilizado e quais destas características são relevantes para os vários tipos de análise. Em seguida, o eletroencefalograma será enquadrado ao arcabouço de Epilepsia. Esta patologia, por sua vez, será introduzida, bem como suas relações relevantes com o registro eletrográfico.

O Capítulo 3 abrange um embasamento teórico sobre duas técnicas, em particular, muito utilizadas em análise de sinais: as Redes Neurais Artificiais e a Transformada *Wavelet*. Ambas estão sendo atualmente muito exploradas pela comunidade científica por adequarem-se à análise de

# 1. INTRODUÇÃO

## 1.1 Motivação

A Epilepsia é uma condição crônica, ou um grupo de doenças, de alta prevalência e, no entanto, ainda pouco conhecida e explicada pela ciência. É bastante comum, por exemplo, que um distúrbio epiléptico seja erroneamente diagnosticado como patologia mental, lesão cerebral, etc. Bittencourt relata [18][19], inclusive, que os hospitais psiquiátricos estão cheios de pacientes tratados como dementes, esquizofrênicos, quando na verdade sofrem apenas de algum tipo de Epilepsia.

Já o sinal de eletroencefalograma (EEG) é o primeiro método de investigação utilizado, na maioria das vezes, na construção de um diagnóstico de Epilepsia. A análise visual do sinal de EEG, porém, consiste em uma tarefa cansativa, demorada e que exige um treinamento prévio por parte do profissional que a realiza, o eletroencefalografista. Neste treinamento, o futuro eletroencefalografista deve aprender a distinguir os vários ritmos do EEG, associados aos estágios do sono, estados comportamentais e mentais, etc. Também aprende a identificar inúmeros tipos de padrões eletrográficos que são indicativos de patologias cerebrais, dentre estes, as espículas e a Epilepsia.

Assim, estão sendo tomadas iniciativas no sentido de se automatizar a análise do sinal de EEG e facilitar o diagnóstico de Epilepsia, por consequência. Estas iniciativas, porém, esbarram nas características próprias deste sinal, as quais dificultam sua análise automática computacional. O EEG é muito afetado por ruídos, tanto provenientes de equipamentos e procedimentos utilizados na própria aquisição, quanto provenientes do próprio paciente (como o ruído muscular, advindo da atividade elétrica dos músculos do paciente). Pode-se, também, descrever o EEG como um sinal complexo e particular em relação aos sinais comumente analisados automaticamente.

A despeito disto, a crença de que esta automatização é possível motivou o presente trabalho.

## 1.2 Justificativas

Apesar de fundamental, o EEG não é considerado pelos clínicos como conclusivo e suficiente para um diagnóstico de Epilepsia pela forte possibilidade de obter-se falsos-positivos e falsos negativos na avaliação dos registros [19]. Isto ocorre devido à dificuldade inerente de análise visual deste EEG, como será visto na sequência, e também devido a duas outras razões:

1. Um paciente não-epiléptico pode apresentar DEs em seu EEG e
2. Um paciente epiléptico pode não apresentar DEs em seu EEG.

Ragazzo [109] relata que, em torno de 80% dos pacientes comprovadamente epilépticos apresentam descargas elétricas interictais, potencialmente epileptogênicas, em seus EEGs. Assim, a importância de se estudar o sinal de EEG para o diagnóstico de epilepsias incide no fato de que normalmente serão encontradas alterações eletrográficas significativas em sinais de EEG de pacientes epilépticos. Porém, não se pode desconsiderar os 20% de pacientes epilépticos que não manifestam anormalidades em seus registros eletroencefalográficos, além dos 2% de indivíduos não-epilépticos que, efetivamente, apresentam descargas epileptiformes, em seus EEGs.

Um dos tipos mais comuns, freqüentes e determinantes de alteração eletrográfica no EEG de pacientes epilépticos é a Espícula (ou *Spike*, em inglês). Este tipo de atividade bioelétrica apresenta morfologia espicular (aguda, rápida) e/ou rítmica (Figura 1.1) e é freqüentemente seguido de uma despolarização de grande amplitude e de baixa freqüência, conhecida como *onda-lenta*. A espícula pode ser detectada através de uma análise visual, pois se destaca da atividade de base do EEG, apesar de possuir características de amplitude e freqüência quantitativamente semelhantes a vários outros padrões eletrográficos do EEG (como será mais detalhado nas Seções 2.3 e 2.5). A espícula normalmente é considerada epileptogênica, ou seja, relacionada a distúrbio epiléptico [45][98].




Figura 1.1– Trecho de EEG com Complexo Espícula-Onda ressaltado (canal do centro, à esquerda).

Também deve-se atentar para a presença de descargas atípicas no EEG não associadas, no entanto, a distúrbios epilépticos. Exemplificando, uma anormalidade nas ondas Delta do EEG pode ser originada por um tumor ou um abscesso, por infarto ou hemorragia, como relata O'Donohoe [98] e por uma série de outras razões, que não um foco epiléptico. Por outro lado, durante uma



crise epiléptica, ou seja, no decorrer do *período ictal*, o EEG apresenta-se geralmente anormal, especialmente se houver alteração da consciência do paciente [104][45].

A observação do sinal durante a crise auxilia enormemente a confirmação do pré-diagnóstico de epilepsia. Porém, a possibilidade de um registro de 30 min. coincidir com a ocorrência de uma crise imprevisível é remota. Por isto, a investigação baseia-se, fundamentalmente, no registro intercrítico. Estudos demonstram, no entanto, que apenas 50% dos registros únicos de rotina conseguem detectar alguma anormalidade interictal no EEG [109][45]. Este valor sobe para 70% de êxito se houver a realização de um segundo registro. Também, em grande parte dos registros de EEG há a influência também de ruído musculares, principalmente em crises tônico-clônicas, implicando na necessidade de utilização de um pré-processamento do sinal, com atenuação por filtragem adequada das componentes interferentes [3]. Ou seja, a qualidade do registro do sinal durante a crise é crucial para o sucesso da análise posterior. Outro ponto importante é que se sabe que o registro pós-ictal de alguns tipos de crises<sup>1</sup> também é anormal e o registro neste período pode ser muito vantajoso, em relação ao registro ictal, porque há diminuição sensível de artefatos de movimento e musculares, o que facilita a interpretação. Então, nenhuma decisão em direção ao diagnóstico deve ser tomada sem que uma série de exames, sob rigorosa inspeção, seja realizada. Também é importante salientar que, em se tratando de diagnóstico de Epilepsia, nenhum exame supera em eficácia a observação clínica associada à uma judiciosa anamnese [18][96].

Em decorrência, no presente trabalho optou-se pela utilização de dados provenientes de monitoração de EEG de longo termo (a qual será explicada na Seção 2.4) e apenas de pacientes adultos (maiores que 21 anos, devido à grande variabilidade das manifestações epileptogênicas em crianças [96], o que demandaria uma abordagem mais sofisticada e complexa no tratamento dos dados) para a abrangência de atuação do sistema.

Neste trabalho entendeu-se que para facilitar a análise computacional do sinal de EEG, levando em conta suas características físicas, as abordagens de análise do EEG devam apresentar características especiais, tais como representação espaço-temporal do sinal adquirido em vários canais; análise não-linear; análise da morfologia do sinal em si e não apenas de características de amplitude e frequência do sinal; capacidade de detecção de eventos; etc. Estas ferramentas computacionais de análise, a princípio, aumentariam as possibilidades de que se obtenha resultados consistentes e conclusivos a partir da análise.

---

<sup>1</sup> P.e, em crises generalizadas do tipo tônico-clônica e crises parciais complexas.

O sistema SIDAPE, proposição deste trabalho, foi concebido, projetado e construído basicamente utilizando-se duas ferramentas que se julgou adequadas à análise de EEGs, por atenderem algumas das restrições acima citadas: as Redes Neurais Artificiais (ANNs) e a Transformada *Wavelet* Rápida (FWT). Sobretudo, observou-se o cuidado em estudar e testar estas ferramentas para melhor aplicá-las, dentro do objetivo geral do sistema. Este seria o de auxiliar na detecção de espículas e outros padrões epileptiformes e assim facilitar o diagnóstico de Epilepsia, no que concerne à análise do EEG.

### 1.3 Objetivos

O objetivo deste trabalho é propor a utilização de determinados métodos, técnicas de análise e processamento de sinais no sentido da implementação de um sistema computacional (SIDAPE – Sistema de Detecção e Análise de Paroxismos em EEG) capaz de auxiliar os especialistas na detecção e na classificação de eventuais Descargas Epileptiformes (DEs), mais especificamente as do tipo Espícula-Onda, presentes no eletroencefalograma (EEG). Isto será feito buscando-se também uma alta confiabilidade na identificação destas espículas, diminuindo as falsas identificações devidas a ruídos externos e musculares, por exemplo.

Este trabalho não tratará do auxílio ao diagnóstico do tipo de crise ou síndrome epiléptica, posto que esta seria uma análise mais complexa, dependente de uma série de outros tipos de exames (tomografias computadorizadas, ressonâncias magnéticas, análises psicológicas, clínicas, etc), o que fugiria do alcance do trabalho. Ainda, o sistema não se aterá aos aspectos etiológicos da investigação neurológica, mas, em contrapartida, será capaz de fornecer ao especialista dados sobre os canais de ocorrência das possíveis espículas, o que possibilita obter-se informações acerca da localização e/ou propagação da atividade epileptogênica no córtex.

Os capítulos subseqüentes tratam com maior detalhamento todas estas questões, descrevem o sistema SIDAPE e os resultados obtidos com a análise automática de EEG, com vistas à detecção de espículas.



## 2. A FISIOLOGIA DO EEG E DAS DESCARGAS EPILEPTIFORMES

### 2.1 O Eletroencefalograma

O registro da atividade elétrica cerebral coletiva dos neurônios cerebrais, ou eletroencefalograma (EEG), pode ser obtido através de três formas: com a introdução de eletrodos no interior do tecido cerebral (registro de Profundidade); através do posicionamento dos eletrodos diretamente na superfície exposta do córtex cerebral (Eletrocorticograma - ECoG), ou de maneira não-invasiva, na superfície do couro cabeludo (o Eletroencefalograma - EEG, Figura 2.13) [30]. Este último método é o mais amplamente utilizado por ser não-invasivo e de custo mais baixo que os outros dois. A sigla EEG será utilizada neste trabalho quando estiver sendo feita referência ao Eletroencefalograma de Superfície.

A rigor, diz-se que o EEG é o resultado da soma dos potenciais pós-sinápticos excitatórios e inibitórios das células do córtex cerebral [34][45], os quais serão explanados na seção seguinte. Pode-se afirmar também que existe uma correlação direta entre as atividades individuais dos neurônios e o EEG [30][45].

### 2.2 Origem do sinal de EEG

A origem do sinal de EEG remonta aos processos elementares de despolarização da membrana celular, no caso, das células nervosas e gliais que compõem o sistema nervoso central (SNC). As células gliais distribuem-se no córtex envolvendo os axônios, somas e dendritos (Figura 2.1) das células nervosas, ou neurônios [128]). Estes estão dispostos em uma espécie de rede, ao longo do córtex, interconectados uns aos outros por meio de seus axônios e dendritos (Figura 2.2). Este fenômeno é conhecido como *conexão sináptica*. Quando um neurônio sofre algum tipo de excitação, ou uma inibição, provocada por algum estímulo externo, esta informação é decodificada em um ou mais trens de pulsos (de frequência dependente da intensidade do estímulo [34][14][45]), ou *potenciais de ação*, que percorrem seu axônio, em direção à extremidade do mesmo, onde existem as sinapses. Lá os impulsos elétricos mais uma vez são codificados em substâncias químicas, os *neurotransmissores*, que vão estimular, por sua vez, os dendritos ou

somas dos neurônios adjacentes (que são denominados *elementos pós-sinápticos*) e que também fazem sinapse com aquele neurônio.




Figura 2.1: Representação esquemática da morfologia e histologia dos elementos neuronais e gliais. (Modificado de *Electroencephalography* [128]).




Figura 2.2: O neurônio biológico e a sinapse.

Ao entrarem em contato com a membrana do neurônio pós-sináptico, estes neurotransmissores vão provocar uma perturbação de origem iônica ou metabólica no potencial de repouso da mesma, acarretando uma *despolarização* (sinapse excitatória) ou uma *hiperpolarização* (sinapse inibitória). O potencial na membrana do neurônio receptor inibido (isto é, tornado ainda mais eletricamente negativo) pelos neurotransmissores é denominado Potencial Pós-Sináptico Inibitório (IPSP, sigla em inglês). No caso de um potencial excitatório (isto é, tornado menos negativo ou despolarizado), utiliza-se o termo Potencial Pós-Sináptico Excitatório (EPSP). À medida que íons extracelulares, resultantes do processo sináptico, vão se dispondo ao longo da membrana (correntes extracelulares), íons intracelulares de mesma carga vão sendo repelidos em direção oposta à da sinapse (correntes intracelulares), originando o potencial de ação no axônio, desta vez no neurônio pós-sináptico [128][45]. O potencial intracelular da membrana dos neurônios normalmente varia de -60 a -70 mV e, dependendo da perturbação, pode sofrer flutuações da ordem de  $\pm 60$  mV. Já o potencial de membrana (PM) das células glia do córtex sofre mudanças induzidas pelo aumento na concentração extracelular de íons de potássio,  $K^+$  (Figura 2.3) [128][45]. Este aumento de concentração de potássio ocorre devido às correntes extracelulares originadas em resposta às correntes intracelulares, geradas durante o processo de ativação dos neurônios, localizados na vizinhança da célula glia em questão [128].




Figura 2.3: Alteração no Potencial de Membrana (PM) de células glia induzida pelo aumento de concentração de  $K^+$  extracelular. A) Potássio é aplicado extracelularmente à célula glia. B) A concentração de potássio aumenta devido à uma ativação da vizinhança neuronal. (Modificado de *Electroencephalography* [128]).



Estes dois fenômenos elétricos são os responsáveis pela geração dos potenciais extracelulares primários (além dos intracelulares), também chamados de *potenciais de campo*, os quais serão captados de forma atenuada no EEG de superfície [128][45][84][124]. Pode-se afirmar que o potencial pós-sináptico é resultado da Integração das séries de impulsos elétricos pré-sinápticos. A geração do sinal de EEG de escalpo em si (conforme Figura 2.4), dá-se através da soma de vários destes potenciais de campo. É importante citar que os potenciais de campo variam com a extensão do neurônio, em decorrência da maior ou menor concentração de íons em um ponto da célula. Isto significa que a atividade elétrica varia em todas as direções da superfície cerebral e também desta até as camadas mais profundas do córtex. Este é o princípio que leva a se optar pela distribuição de eletrodos em todo o escalpo e também intracorticalmente se for o caso, para captação de sinais.

Com relação à Epilepsia, o aparecimento de ondas de alta frequência e amplitude (ou espículas - vide seções seguintes) no EEG implica na existência de um grupo de células nas quais ocorrem alterações episódicas e sincronizadas da frequência dos potenciais, ou *descargas*. Estas anormalidades são denominadas de *Alterações Paroxísticas Despolarizantes* (APD). As APDs ocorrem de maneira repetitiva e estereotipada em neurônios situados na área do foco epiléptico e têm propagação variável no córtex: limitada e lenta, no caso de distúrbio focal (localizado em uma área restrita do cérebro, inicialmente [118]), ou imediata e ampla, no caso de distúrbio generalizado (inicialmente já envolve os dois hemisférios cerebrais [118]).




Figura 2.4: Princípio de geração dos sinais. Eletrodos:  $E^1$  e  $E^2$  - registram os potenciais intracelulares das fibras aferentes;  $E^3$  e  $E^4$  - potenciais de membrana (PM) dos elementos dendríticos;  $E^5$  - potencial de campo.

Grupos síncronos de potenciais de ação nas fibras aferentes geram sinais EPSPs, resultantes da integração destes potenciais, nas áreas dendríticas e correspondentes potenciais de campo nos registros EEG e DC/EEG.

(Modificado de *Electroencephalography* [128]).

## 2.3 Fisiologia do EEG

Quanto às suas características físicas, o EEG superficial (de escalpo) em humanos ocupa uma banda em frequência de 0 a 100 Hz, com uma concentração de energia do sinal entre 0,5 e 60 Hz [128]. Isto significa que as frequências do EEG ocupam uma banda próxima, ou mesmo superposta, às bandas de outros sinais bioelétricos de origem cefálica, como Eletromiograma (EMG) de superfície, Eletro-Oculograma (EOG), etc. Estes sinais são também captados durante o registro do sinal de EEG, o que dificulta a análise do mesmo. O sinal de EEG no couro cabeludo é captado com uma diferença de potencial de 50  $\mu\text{V}$  em média, mas a faixa de amplitudes varia de 2 a 200  $\mu\text{V}$  [30], aproximadamente. Isto representa 10%, aproximadamente, da magnitude de um sinal de eletrocardiograma (ECG) [98], o que demonstra a dificuldade na captação do EEG e a necessidade da utilização de bons amplificadores e filtros para redução de ruídos (estes últimos também chamados de *artefatos* – vide Seção 2.3.3) nos sistemas de aquisição deste tipo de sinal.

### 2.3.1 Características físicas dos ritmos comuns em EEG

As características de amplitude e frequência do sinal de EEG são influenciadas pela região do córtex cerebral a partir de onde foi captado o registro, pela idade e pelos estados físicos (sono, vigília, coma, etc) e comportamentais (depressão, excitação, euforia, stress, etc) do indivíduo. Os sinais de EEG variam de paciente para paciente, mesmo sob circunstâncias idênticas e variam também em um mesmo paciente, de um momento para outro. Por estas e outras razões é difícil estratizar-se os padrões relacionados à normalidade e comuns no EEG (Figuras 2.5 e 2.6). Estes geralmente apresentam uma relativa regularidade em frequência, morfologia e amplitude, sejam estas quais forem. Então, o espectro de frequências do EEG é normalmente subdividido em faixas de frequência [45] que podem estar relacionadas a diversos estados físicos e comportamentais, conforme segue:

*Banda Alfa - 8 a 13 Hz* - Ritmo comum em pacientes normais, e mais facilmente observável estando o indivíduo acordado, relaxado e com os olhos fechados.

*Banda Beta - 13 a 22 Hz* - Ritmo comum em pacientes adultos normais, durante o estado de vigília. Dominante na região pré-central do cérebro, mas aparece também em outras regiões cerebrais. Subdivide-se em

*Beta I - 13 a 17 Hz* - presente durante intensa ativação do Sistema Nervoso Central (SNC);

*Beta II - 18 a 22 Hz* - diminui durante intensa ativação do SNC.

*Banda Teta* - 4 a 8 Hz - Ritmo freqüente em crianças, nas regiões central e temporal. Típico de estágios iniciais do sono. Alguns transientes de componentes deste ritmo têm sido encontrados em pacientes adultos normais.

*Banda Delta* - 0,5 a 4 Hz - Ritmo comum em crianças pequenas, em pacientes em estado de sono profundo e em portadores de patologias cerebrais. A presença desta onda em adultos sob estado de alerta pode indicar anormalidades.

Quando formas de onda se destacarem abruptamente em amplitude, freqüência ou morfologia destas *atividades de fundo* normais do EEG diz-se que ocorreu um *paroxismo* [34].

A faixa de freqüência crítica para Epilepsia em um EEG é de 2 a 20 Hz, isto é, esta é a faixa de concentração do espectro de potência das componentes das descargas epileptiformes.

Além destes ritmos relacionados à atividade de fundo, pode-se citar outros ritmos observáveis em indivíduos normais ou não, mas com morfologias especiais, tal como descrito na próxima seção.




Figura 2.5: Exemplos de atividade (a) delta, (b) teta, (c) alfa e (d) beta. (e) Bloqueio do ritmo alfa através de abertura dos olhos. (f) Marcador de 1 segundo de tempo e calibração. (Modificado de *EEG Technology* [34]).






Figura 2.6: Os estágios do sono no EEG (1 a 4 ou A a D e E). (Modificado de Catálogo da Produtos Roche, Ltda, Londres).

### 2.3.2 Características físicas dos ritmos especiais em EEG

O EEG pode apresentar vários sinais peculiares e particulares que não necessariamente estão relacionados a anormalidades, porém são típicos de várias situações de estados físicos e comportamentais do paciente. Devido ao formato característico destes sinais a identificação destes é possibilitada quando se destacam do ritmo dominante, como mostra a Figura 2.7. As observações sobre os sinais típicos foram extraídas de Cooper [34].




Figura 2.7: Exemplos de formas de onda específicos (eletrodo de referência no queixo). (a)Complexos-K; (b) Onda Lambda; (c)Ritmo mu; (d)Espículas; (e)Ondas Agudas; (f)Atividade Espícula-Onda repetitiva; (g)Fusos do Sono; (h)Ondas Agudas do Vértex; (i)Descargas Poliespícula. (Modificado de *EEG Technology* [34]).

Os *Complexos-K* consistem de ondas lentas de grandes amplitudes (um ou dois picos de tensão com amplitudes de cerca de 100 a 200 $\mu$ V, normalmente) mescladas à atividade de alta frequência e geralmente seguidas por atividades de 12 a 14 Hz. Estes complexos ocorrem espontaneamente ou em resposta a estímulos súbitos, durante o sono (tipicamente no terceiro estágio de sono) [34].

As *ondas Lambda* são sinais ocorrentes na região occipital, relacionados aos movimentos oculares e à exploração visual. A morfologia é de ondas agudas, com períodos positivos, de menos de 50 $\mu$ V .

O *ritmo Mu* lembra um formato de pente, com arcos de 7-11 Hz, e ocorre no lobo central. A amplitude também é, geralmente, menor que 50 $\mu$ V. Este ritmo está relacionado à estimulação ou movimentos tácteis das mãos.

As *espículas*, *ondas agudas* (ou *sharp*), *complexos poliespícula* (CPE), *complexos espícula-onda* (CEO) e *complexos poliespícula-onda* (CPEO) estão relacionados, geralmente, a vários episódios epileptogênicos. A diferença básica entre espículas e ondas *sharp* está na duração do paroxismo, ou, em outras palavras, a espícula seria mais rápida que a onda aguda.

*Os fusos do sono*, que ocorrem em determinados estágios do sono (tipicamente no primeiro estágio), são surtos de alta frequência, ondas rítmicas de 14 Hz e aproximadamente 100 $\mu$ V, com morfologia senoidal.

As *ondas agudas do vértex* (ou *Ondas-V*, devido ao formato), como o próprio nome diz, ocorrem na região do vértex e são negativas em relação às demais regiões do córtex. São associadas geralmente aos estímulos do despertar [96].

Além destes padrões relacionados à atividade cerebral de indivíduos, eventos externos indesejados podem ser registrados junto com o EEG. Estes eventos, os *artefatos* ou *ruidos*, podem inclusive levar a interpretações errôneas ou duvidosas dos estados físicos e comportamentais relacionados ao indivíduo em questão. É necessário, portanto, que a morfologia e a origem destes artefatos seja bem conhecida pelo eletroencefalografista e que se diminua ao máximo a interferência destes artefatos nos registros de EEG.

### 2.3.3 Artefatos presentes no EEG

Por definição, um artefato em eletroencefalografia é todo e qualquer potencial elétrico registrado, o qual não foi originado a partir do cérebro [34]. As possíveis fontes de artefatos conhecidas são quatro [34][112][137]:

- *O equipamento de EEG*: Artefatos gerados a partir do mau funcionamento do equipamento de aquisição e/ou monitoração de EEG são chamados de *faltas*. Estas faltas podem ocorrer por inúmeras razões e dependem do equipamento. Algumas faltas comuns são as decorrentes de falhas no suprimento de energia da máquina, ruidos em chaves, calibradores e amplificadores, etc.
- *Interferências elétricas externas*: Tais interferências podem ser de ordem eletrostática ou eletromagnética. A fonte de interferência externa mais comum é a própria frequência de oscilação da rede, ou *interferência de 60 Hz*. Estes artefatos devem ser previstos e estudados já



no projeto do equipamento e do recinto onde serão realizados os exames, para que possam ser eliminados através de isolações, blindagens e filtragens.

- *Eletrodos:* Os eletrodos devem oferecer a mínima impedância possível ao sinal de EEG, o qual é de baixa amplitude. Esta impedância depende da qualidade dos eletrodos (material do qual são feitos, que deve ser bastante condutivo, contatos, aspectos construtivos, etc.), da qualidade da substância condutora utilizada para melhorar o contato entre o eletrodo e a pele (geralmente, um gel condutor), do estado da pele (excesso ou não de pêlos, suor, etc.) e, principalmente, da perícia e do cuidado do operador na colocação dos eletrodos (Figura 2.8).

- *O paciente:* Artefatos extra-cerebrais nos próprios pacientes são gerados, normalmente, a partir de atividade elétrica muscular, seja devido aos movimentos dos olhos (EOG - artefato mais comum no EEG [137]), seja por movimentos dos membros do corpo, ou até devido à atividade cardíaca. É muito importante, portanto, que o paciente seja mantido o mais relaxado possível, durante a realização do exame e que o clínico saiba reconhecer os artefatos musculares, que são, geralmente, de grandes frequência e amplitude (Figuras 2.9, 2.10 e 2.11).




Figura 2.8: Artefatos provenientes de eletrodos e de cabos condutores de entrada; (a) devido a movimento dos eletrodos; (b) devido a contato pele-eletrodo imperfeito; (c) devido à contaminação por contato entre eletrodo e cliques; e (d) devido à contaminação por contato entre plugue de entrada e soquete. (Modificado de *EEG Technology* [34]).




Figura 2.9: Deflexões típicas produzidas por movimentos verticais e laterais dos olhos em canais dispostos nas regiões frontais e temporais (Modificado de *EEG Technology* [34]).




Figura 2.10: (a) Exemplos de atividade muscular registrados a partir de eletrodos no escalpo. (b) O efeito da atenuação de alta-frequência (filtragem passa-baixas com atenuação das componentes de frequência superiores a 25 Hz) na atividade muscular mostrada no traçado superior. (Modificado de *EEG Technology* [34]).




Figura 2.11: Artefatos devidos à atividade cardíaca. (a) Artefatos de pulsação em um mesmo indivíduo. (b) Artefatos de ECG em um mesmo indivíduo. (Modificado de *EEG Technology* [34]).



## 2.4 A Eletroencefalografia

Os primeiros registros de EEG em humanos (Figura 2.12) foram realizados por Hans Berger, em 1924 [53][14], o que representou um grande passo no caminho do diagnóstico e tratamento de patologias neurológicas.




Figura 2.12: O primeiro registro eletroencefalográfico realizado em humanos, por Berger. (Original de Berger, 1929 [14]. Modificado de *Eletroencephalography*, 1993 [97])

Outro trabalho notável na área foi desenvolvido em 1952, pelo casal Gibbs [52], na forma de um *Atlas de eletroencefalografia*. Este livro já se propunha a descrever padrões eletrográficos e relacioná-los a determinados tipos de crises epiléticas. Inúmeros trabalhos foram publicados [67][66][85][83][79][33][55][58][87][103][115][46][4][108], nos anos subseqüentes, na tentativa de se minimizar a tarefa de interpretação do sinal de EEG, este sem pré-processamento. Além disto, à medida que aumentava a utilização do EEG, enquanto ferramenta auxiliar da Neurologia, crescia também a tecnologia envolvida no desenvolvimento de equipamentos capazes de adquirir, amplificar e processar estes sinais.

No Brasil, um registro de EEG ambulatorial de rotina usualmente tem duração de 30 minutos, durante os quais segue-se um protocolo de alternância de montagens de eletrodos (Figura 2.13), isto é, adquire-se inicialmente o sinal a partir de uma dada configuração de eletrodos, para, em seguida, alterar-se esta configuração e adquirir-se o sinal a partir de outros eletrodos/canais e assim por diante.




Figura 2.13: Disposição de eletrodos no escalpo e nomenclatura do sistema 10-20 Internacional letra-número: Números ímpares à esquerda, pares, à direita e Z ou 'zero', na linha mediana. (a) Oito; (b) Treze e (c) Dezesesseis eletrodos. (Modificado de *Eletroencephalography*, 1993 [97]).

Existem, basicamente, três formas de se estabelecer a relação entre eletrodos e canais, quais sejam: método bipolar, método unipolar (ou de eletrodo/referência comum) e método de referência média [34]. No método bipolar cada canal é captado a partir de 2 eletrodos que podem ser afetados por sinais cerebrais localizados no escalpo (Figura 2.14(a)). Isto significa que o sinal registrado no canal  $V_1$ , por exemplo, é igual à diferença de potencial entre os eletrodos  $e_1$  e  $e_2$ , e assim por diante. Já no método unipolar (Figura 2.14(b)), todos os canais são resultantes da diferença de potencial entre os eletrodos localizados no escalpo ( $e_1, e_2, \dots, e_n$ ) e um determinado eletrodo de referência comum ( $e_r$ ), o qual deve ser localizado em um local de mínima possibilidade de ocorrência de potencial advindo do cérebro ( $e_r \rightarrow 0$ ), como por exemplo, no queixo ou no lóbulo da orelha, etc. Por fim, no método de referência média, utilizado por Wilson *et al.* [142] a partir de 1934, deriva-se um eletrodo de referência resultante do potencial médio de todos os demais eletrodos (Figura 2.14(c)), o que significa que o sinal adquirido no canal  $V_1$ , por exemplo, será resultante da diferença de potencial entre o eletrodo  $e_1$  e o potencial médio entre todos os eletrodos.




Figura 2.14: (a) Método bipolar de ligação de eletrodos ( $e_i$ ) no escalpo. Conexões de entrada do amplificador de EEG representadas por  $V_i$ . (b) Método unipolar ou de eletrodo comum ( $e_r$ ). (c) Sistema de Referência Média Comum ( $e_{ar}$ ). (Modificado de *EEG Technology*, 1974 [34])

Em exames de rotina são utilizados normalmente 16 canais, mas não há restrições quanto ao número de canais<sup>2</sup>, a não ser a qualidade e resolução do sinal adquirido.

<sup>2</sup> Tipicamente são utilizados de 8 a 16 eletrodos arranjados em 6 a 32 canais. Em procedimentos de Mapeamento Cerebral, por exemplo, são comuns montagens que utilizam 20, 32 ou até 64 eletrodos. O SIDAPE utiliza arquivos com 27 eletrodos montados em 24 e 32 canais.



Um outro conceito em termos de registros de EEG é o que defende a necessidade da monitoração por longo tempo do EEG de pacientes sob investigação de epilepsia. Muitos especialistas na área propõem a monitoração de EEG por períodos de tempo superiores a 30 min. e a flexibilização da alternância de montagens dos eletrodos [104][45]. Por exemplo, pode-se constatar *in loco* que, no *Montreal Neurological Institute* (MNI), Canadá, os registros para diagnóstico de epilepsia têm duração de duas a quatro semanas, período durante o qual o paciente permanece internado na Clínica e sob constante observação. Além do EEG, câmeras de vídeo registram todas as atividades do paciente e inclusive, possíveis ocorrências de crises epiléticas clínicas e comportamentos patológicos associados à Epilepsia. As desvantagens desta proposta dizem respeito, principalmente, à imobilidade forçada a que tem que se submeter o paciente durante o exame e ao grande volume de dados, na forma dos registros, gerado pela monitoração. Em resposta a esta necessidade, estão sendo desenvolvidos sistemas de *radiotelemetria* [15][98][104][61][72][34][45], que permitem a livre movimentação do paciente (já que não existe conexão física entre os eletrodos instalados no escalpo e o equipamento) e que são capazes de armazenar os dados de EEG em disco de computador, o que facilita sobremaneira a análise posterior.

## 2.5 Introdução à Epilepsia

O conceito de Epilepsia foi e permanece sendo um tema gerador de controvérsias no meio médico. Por muitos séculos aceitou-se como epilético apenas o paciente que apresentasse crises de perda de consciência acompanhadas de convulsões generalizadas. Com a verificação de que alguns pacientes apresentavam episódios de obnubilação da consciência ou *ausências* [88], alternadamente com as crises convulsivas generalizadas, este conceito foi-se alargando para contemplar as várias síndromes epiléticas distintas já identificadas.

Entretanto, o primeiro cientista a desmistificar o mecanismo das epilepsias foi o inglês Hughlings Jackson [73][98] em 1870, ao reconhecer como evento comum a todas as formas desta doença a ocorrência de descargas excessivas e desordenadas dos neurônios cerebrais, independentemente das diferentes manifestações clínicas e peculiaridades funcionais das áreas e formações nervosas do cérebro postas em ação pelas descargas elétricas, características de cada tipo de epilepsia [88].

Muitos estudos e muita polêmica seguiram o trabalho de Jackson, tanto acerca da etiologia (estudo das origens, das causas da doença), como da semiologia (estudo e descrição dos sinais da

doença, sintomatologia) da Epilepsia. Surgiram inúmeros conceitos e múltiplas classificações para as epilepsias, tais como *grande-mal* e *pequeno-mal*, Epilepsia Sintomática ou Idiopática, Epilepsia Psicomotora ou equivalentes epiléticos, Hipsarritmia, Disritmia Cerebral Paroxística, etc. Muitas destas idéias foram contestadas e algumas foram postas por terra [19], especialmente por Penfield e Jasper [103], do Instituto Neurológico de Montreal (MNI), nas décadas de 40 e 50, os quais reformularam algumas destas definições e retomaram idéias de Jackson. Alguns destes conceitos e classificações, porém, persistem até hoje em algumas escolas. Enfim, a concepção atualmente mais aceita é a que afirma a Epilepsia como sendo “uma condição crônica, ou um grupo de doenças que têm em comum a ocorrência de crises epiléticas” [61]. Estas sim são definidas como resultantes “da ativação de circuitos neuronais por um mecanismo que se traduz no EEG por descargas hipersíncronas de tendência repetitiva e, clinicamente, por manifestações cuja expressão (motora, sensitivo-sensorial, modificações súbitas do estado da consciência e seqüências comportamentais realizadas inconscientemente) depende dos circuitos postos em atividade” [88]. É necessário salientar que o que caracteriza propriamente a Epilepsia é o caráter recorrente das crises epiléticas, na ausência de doença tóxico-metabólica ou febril. Isto significa que uma “crise única não é considerada epilepsia” [61][17] e nem crises ocorridas na presença de outras patologias não-epiléticas o são.

### **2.5.1 Nomenclatura e Terminologia**

Faz-se necessário um esclarecimento acerca dos significados dos inúmeros termos empregados na seqüência deste trabalho, segundo a bibliografia médica [61][109][104][45]:

#### **Termos utilizados quanto à Etiologia da Epilepsia: [61]**

- Epilepsia Idiopática - refere-se às classes de Epilepsias transmitidas geneticamente;
- Epilepsia Sintomática - tipo de epilepsia cuja etiologia é determinada;
- Epilepsia Criptogênica - refere-se à epilepsia de presumível base orgânica, porém de etiologia indeterminada.

#### **Termos utilizados para Descargas Atípicas no EEG: [109] [45]**

- Paroxismo - atividade eletrográfica que se destaca visivelmente da atividade de base do EEG. Refere-se tanto a descargas epileptogênicas, quanto a fusos do sono, Complexos-K, etc;
- Espícula - onda aguda, geralmente de grande amplitude, rápida (até 70 ms. de duração, geralmente), com períodos de polaridades positivas e negativas, sendo estes últimos mais proeminentes;



- Complexo Espícula-Onda (CEO) - padrão eletrográfico composto de uma espícula seguida por uma descarga única de onda lenta polimorfa, ou sobreposta no período ascendente desta;
- Complexo Poliespícula (CPE) - formação característica de várias espículas agrupadas;
- Complexo Poliespícula-Onda (CPEO) - múltiplas espículas seguidas ou sobrepostas no período ascendente de uma onda lenta polimorfa;
- Descarga Epileptiforme (DE) - atividade que apresenta morfologia espicular ou rítmica. Não necessariamente epileptogênica, mas considerada apenas como variante da normalidade. Exemplos de DEs: *small sharp spikes*, atividade variante psicomotora (ritmo teta em adultos), espículas positivas de 6-14 Hz, CEO lentos de 6 Hz;
- Descarga Epileptogênica (DEg)- atividade paroxística efetivamente associada e/ou originada por distúrbios epilépticos.

**Termos utilizados quanto à investigação clínica: [104]**

- Diagnóstico etiológico - investigação que se destina à identificação do(s) agente(s) causador(es), da origem das crises epilépticas;
- Diagnóstico do tipo de crise - refere-se à identificação, classificação e estratificação do tipo de crise, epiléptica ou não, que acomete o paciente.

A terminologia e a classificação das epilepsias modificaram-se substancialmente durante os anos e atualmente são utilizados 3 tipos de classificações diferentes, as quais são referentes, respectivamente, aos tipos de Crises Epilépticas, aos tipos de Epilepsias, Síndromes e condições relacionadas e às Localizações das Crises nos Lobos cerebrais. A classificação das crises atualmente utilizada é recomendada pela *International League Against Epilepsy* (ILAE) [70][61][45], desde 1981, conforme descreve a Tabela 2.1. A classificação quanto ao tipo de epilepsia, síndrome ou condição relacionada é chamada de *Classificação Internacional* [71][45] e está relacionada na Tabela 2.2. Por fim, para se estratificar uma epilepsia em relação ao Lobo no qual esta localiza-se é utilizada a classificação descrita na Tabela 2.3. Todas as tabelas foram extraídas de *Epilepsia* [61].

---

*Tabela 2.1: CLASSIFICAÇÃO DAS CRISES EPILEPTICAS*

---

1. Crises Parciais (ou Focais, ou Locais)
    - Crises parciais simples (CPS) - consciência preservada
      - motoras
      - sensitivas
      - autonômicas
      - psíquicas
    - Crises parciais complexas (CPC) - consciência alterada
      - Início de crises parciais simples seguida por alteração na consciência
      - Alteração de consciência no início
    - Secundariamente generalizadas
      - CPS evoluindo para crises tônico-clônicas generalizadas(CTCG)
      - CPC evoluindo para CTCG
      - CPS evoluindo para CPC e então para CTCG
  2. Crises Generalizadas (desde o início)
    - Crises tônico-clônicas generalizadas
    - Crises de ausência
    - Crises de ausência atípicas
    - Crises mioclônicas
    - Crises tônicas
    - Crises clônicas
    - Crises atônicas
  3. Crises não Classificáveis
- 

---

*Tabela 2.2: CLASSIFICAÇÃO INTERNACIONAL DAS EPILEPSIAS E SÍNDROMES EPILEPTICAS E CONDIÇÕES RELACIONADAS*

---

1. Síndromes e Epilepsias Localizadas (locais, focais, parciais)
    - IDIOPÁTICA (início relacionado à idade)
      - Epilepsia Benigna na Infância com Espícula Centro-Temporal
      - Epilepsia da Infância com paroxismos occipitais
      - Epilepsia Primária da Leitura
    - SINTOMÁTICA
      - Epilepsia Parcial Contínua Progressiva Crônica
      - Síndrome c/ Crises c/ Quadros Específicos de Manifestação
        - Epilepsias Lobo Temporal
        - Epilepsias Lobo Frontal
        - Epilepsias Lobo Parietal
        - Epilepsias Lobo Occipital
    - CRIPTOGÊNICAS
  2. Síndromes e Epilepsias Generalizadas
    - IDIOPÁTICA (início relacionado à idade)
      - Convulsão Familiar Neonatal Benigna
      - Convulsão Neonatal Benigna
      - Epilepsia Mioclônica Benigna do Lactente
      - Epilepsia Ausência da Infância
      - Epilepsia Ausência Juvenil
      - Epilepsia Mioclônica Juvenil
      - Epilepsias Com Crises Tônico-Clônicas ao Despertar
      - Outras Epilepsias Idiopáticas Generalizadas
      - Epilepsias Desencadeadas Por Modos Específicos de Ativação
    - CRIPTOGÊNICA OU SINTOMÁTICA
-

- 
- Síndrome de West
  - Síndrome de Lennox-Gastaut
  - Epilepsia com Crises Mioclônico-astáticas
  - Epilepsia com Ausências Mioclônicas

#### SINTOMÁTICAS

Etiologia inespecífica

- Encefalopatia Mioclônica Precoce
- Encefalopatia Epiléptica Infantil Precoce c/ Surto-supressão
- Outras Epilepsias Generalizadas Sintomáticas
- Síndromes específicas
- Crises Epiléticas Complicando Outras Doenças

#### 3. Síndromes e Epilepsias Indeterminadas se Focais ou Generalizadas

##### COM CRISES FOCAIS E GENERALIZADAS

- Crises Neonatais
- Epilepsia Mioclônica Severa do Lactente
- Epilepsia c/ Espícula-onda Lenta Contínua Durante Sono Lento
- Afasia Epiléptica Adquirida
- Outras Epilepsias Indeterminadas

##### CRISES NÃO CARACTERIZADAS COMO FOCAIS OU GENERALIZADAS

#### 4. Síndromes Especiais

##### CRISES CIRCUNSTANCIAIS

- Convulsões Febris
  - Crises Isoladas ou Estado de Mal Isolado
  - Crises Ocorrendo Somente em Evento Tóxico ou Metabólico
- 

---

*Tabela 2.3: PRINCIPAIS CARACTERÍSTICAS CLÍNICAS DAS CRISES COM RELAÇÃO À LOCALIZAÇÃO NOS LOBOS*

---

#### Crises de Lobo Frontal: CPS $\pm$ CPC $\pm$ CTCG

Movimentos adversivos da cabeça, manifestações motoras proeminentes particularmente nas pernas. Crises freqüentes (muitas ao dia), com duração de segundos. Apesar da alteração de consciência há pouca confusão pós-crítica.

#### Crises de Lobo Parietal: CPS $\pm$ CTCG

Sintomas sensitivos e motores (com marcha jacksoniana). Algumas vezes com sensações dolorosas.

#### Crises de Lobo Temporal: CPC $\pm$ CTCG

Sensação epigástrica, alucinações olfatórias ou gustativas, *déjà vu*, *jamais vu*, automatismos alimentares, alucinações visuais e confusão pós-ictal proeminente.

#### Crises de Lobo Occipital: CPS $\pm$ CTCG

Fenômenos visuais simples: brilho, relâmpago, pisca-pisca, clarão.

---



### **2.5.2 Relações entre as epilepsias e o EEG**

Dentre os paroxismos que podem estar presentes em um registro de EEG, podemos destacar os seguintes como significativos para o diagnóstico de epilepsia [109][45]:

- Complexos Espícula-Onda (CEO) Lentos de 3 Hz - ocorrem geralmente em casos de crises de ausência, na infância e na adolescência [118];
- CEO Lentos de 1,5-2,5 Hz - paroxismos focais, ou multifocais, repetitivos, que se manifestam geralmente nos lobos frontais, em crianças e adolescentes;
- CEO Lentos de 3,5-6 Hz - paroxismos associados a crises mioclônicas e tônico-clônicas generalizadas. Podem vir acompanhados de complexos poliespículas (CPE);
- Espículas e Poliespículas de 10-20 Hz - normalmente presentes em crises atônicas e tônico-clônicas;
- Hipsarritmia - padrão eletrográfico totalmente desorganizado, com a presença de descargas de grandes amplitudes, “quase contínuas, de espículas e poliespículas, bilaterais” (nos dois hemisférios cerebrais) [98]. A hipsarritmia é altamente indicativa de epilepsia e característica de crianças de 3 meses a 4 anos de idade que sofrem de espasmos infantis.



### 3. FERRAMENTAS DO TRABALHO

#### 3.1 Redes Neurais Artificiais

##### 3.1.1 Introdução

Há alguns anos, a comunidade científica mundial tornou a reconhecer a importância da aplicação de técnicas de Inteligência Artificial (IA), na resolução daqueles problemas que não seriam facilmente solucionados pela utilização de técnicas e ferramentas convencionais. As técnicas de IA recebem esta denominação pelo fato de tentarem “imitar” a maneira pela qual o homem soluciona problemas. E especialmente problemas que a máquina, utilizando técnicas convencionais, tem dificuldade em processar, tais como *reconhecimento de padrões*, manipulação de variáveis qualitativas, etc.

Existem três abordagens básicas para a análise por Inteligência Artificial: os Paradigmas *Simbólico*, *Conexionista* e *Evolucionário* [11].

A abordagem *Simbólica Baseada em Regras* (a qual é o tipo mais conhecido de abordagem simbólica, dentre os muitos existentes para este paradigma) procura definir um determinado sistema através de *regras de produção* simples (do tipo “SE-ENTÃO”) elicitadas a partir do conhecimento de um especialista ou grupo de especialistas, para permitir a descrição das variáveis qualitativas e a tomada de decisões (com inspiração humana) sobre estas variáveis. Por exemplo, para um sistema procedimental e convencional baseado em computador seria muito difícil decidir-se por um ou por outro diagnóstico, da maneira como um médico (o *especialista* em questão) faria rotineiramente. Porém, se as regras para se chegar a este diagnóstico (exemplo simplificado: “SE há febre E há dor-de-cabeça ENTÃO diagnóstico = gripe”) puderem ser definidas, o programa de computador poderá compilar todas estas regras, criando um *Sistema Especialista* e, em tese, chegar a pelo menos uma hipótese de diagnóstico para cada caso específico. Pode-se citar como exemplo o Sistema Especialista para diagnóstico de Epilepsia desenvolvido no Grupo de Pesquisas em Engenharia Biomédica da UFSC, como trabalho de dissertação de mestrado [22].

O Paradigma Conexionista, por sua vez, também procura imitar o discernimento humano, mas sem o estabelecimento de nenhuma regra verbal conhecida de condução da tomada de decisão. A abordagem conexionista age de forma semelhante ao cérebro humano, que não precisa consultar

regras de conduta, ou de produção (pelo menos, conscientes) a todo instante, para seguir um procedimento.

Apenas ocorre o “processamento” instantâneo de informações de entrada, resultando em ações de saída intuitivas, na maior parte das vezes. Tanto isto ocorre que, por exemplo, é muito difícil para um médico experiente explicar em palavras *de que maneira* opta por um diagnóstico específico, frente a uma determinada condição clínica. Outro exemplo é o processo de visão humana: a informação luminosa é captada nas retinas dos olhos e conduzida na forma de impulsos elétricos por meio dos nervos ópticos, quiasmas ópticos, tratos ópticos cujas fibras fazem sinapse no corpo geniculado lateral do tálamo, o qual, por sua vez, envia fibras nervosas até o córtex visual, localizado no lobo occipital do cérebro. Enfim, segue através de uma extensa e complexa rede de neurônios, até que se obtenha uma saída definitiva (ação, percepção, sentimento, etc) para os dados de entrada. O que acreditam os cientistas da área Neurológica, é que cada experiência vivida pelo ser humano resulta no estabelecimento de *conexões sinápticas* entre neurônios. Se as experiências forem se repetindo, as conexões são fortalecidas. Caso contrário, as conexões são enfraquecidas com o tempo. Este processo é chamado de *Aprendizagem* ou *Treinamento*.

As Redes Neurais Artificiais, portanto, consistem de um ou mais conjuntos de “neurônios” artificiais interconectados, geralmente dispostos em “camadas” formando redes, que uma vez devidamente *treinadas* são capazes de processar matematicamente dados de entrada ao longo das camadas até que estes atinjam a camada de saída da rede, onde será disponibilizada a “resposta” da rede. Ou nas palavras de De Azevedo [39]: “Redes neurais são sistemas complexos, constituídos por elementos representando algumas das características dos neurônios que constituem o sistema nervoso dos seres vivos e permitindo sua interação com o ambiente que os cerca”

A Computação Evolutiva, ou Evolucionária, baseia-se em simulação, via programas de computador, do processo Evolutivo<sup>3</sup> que deu origem às espécies que hoje habitam o planeta Terra. Simplificando, cria-se uma “população virtual” de “indivíduos” com características aleatórias distintas entre si (que lhe atribuem uma determinada “aptidão”). Estas entidades nascem, sofrem mutações, reproduzem-se e morrem; tal como qualquer ser vivo; só que virtualmente. E após os “cruzamentos” entre estas entidades, o programa deve identificar quais dentre os novos indivíduos gerados seriam mais “resistentes”, ou “aptos”, a um determinado “meio-ambiente” e quais aqueles que, por não possuírem as características necessárias à sobrevivência tenderão a extinguir-

---

<sup>3</sup> Esta teoria foi desenvolvida por Charles Darwin [35] e estabeleceu as bases para o que hoje chamamos de *Genética*. Darwin estudou o mecanismo natural que selecionou, ao longo dos tempos, as espécies mais “aptas” ou “adaptáveis” dentre todas as que existiram, e como estas foram capazes de transmitir seus genes às gerações posteriores, ao contrário de espécies mais “fracas” ou “menos adaptáveis”, que se extinguiram.



se. Desta forma, após várias “gerações”, ou iterações do programa, pode-se identificar as entidades “otimizadas”, ou que “evoluíram”. Este paradigma tem sido bastante aplicado, justamente, à otimização de processos [11]. Atualmente, os algoritmos evolutivos também têm sido aplicados na otimização do treinamento de Redes Neurais Artificiais, o que permite um maior controle sobre o desempenho que a rede vai alcançar [11].

Uma quarta abordagem, que vem sendo muito utilizada nos últimos anos, é a Híbrida, ou seja, que utiliza dois ou mais paradigmas de Inteligência Artificial simultaneamente. No presente trabalho a abordagem Híbrida empregará os Paradigmas Conexionista e Simbólico, tal como vários trabalhos científicos têm feito, nos últimos anos [99][100][89][102][21]. Esta abordagem oferece a vantagem de aproveitar as características mais fortes de cada paradigma, onde estas forem mais necessárias. Por exemplo, onde existirem variáveis relevantes e regras explícitas acerca destas variáveis para uma tomada de decisão, pode-se utilizar uma abordagem simbólica. Já, por exemplo, onde não sejam conhecidas as regras de produção ou estas sejam muito complexas, pode-se aproveitar a abordagem conexionista. A interação entre ambas as abordagens deve ser feita segundo as características particulares de cada sistema e universo de análise.

Conforme a proposta de De Azevedo [39], será feita uma breve introdução acerca de Neurônios e Redes Neurais Artificiais (RNAs). Esta abordagem baseia-se na Teoria de Sistemas e utiliza conceitos de Teoria de Grafos.

### 3.1.2 Modelos de Neurônios

A construção de redes neurais artificiais (RNAs) tem forte inspiração nos neurônios biológicos e nos sistemas nervosos. Entretanto, as semelhanças entre as RNAs e as redes neurais naturais (RNNs) atualmente são mínimas, muitas vezes.

O primeiro modelo de neurônio foi proposto por McCulloch e Pitts, em 1943 [93], com a intenção de imitar a realidade biológica, ou seja, os processos cognitivos do SNC. Este modelo interpretava o funcionamento do neurônio como sendo um sistema binário (Figura 3.1). A entrada efetiva (*net\_input*) do neurônio é resultado de uma soma ponderada de várias entradas binárias:

$$\text{entrada efetiva} = u = \text{net\_input} = \sum_{i=1}^n w_i u_i \quad (\text{Eq. 3.1})$$

A entrada efetiva sofre um retardo  $D$ , inspirado no atraso devido à difusão através da sinapse dos neurotransmissores e que na maioria das vezes pode ser desprezado. Esta entrada atrasada de  $D$  é o argumento para a função de transferência do modelo de neurônio, cuja saída é também binária (Figura 3.1).




Figura 3.1: Modelo de neurônio artificial de McCulloch e Pitts (Modificado de Barreto [12]).

Após McCulloch e Pitts, vários pesquisadores como Hebb [65] e Rosenblatt [116] propuseram seus próprios modelos de neurônios e RNAs. O modelo geral de neurônio proposto por De Azevedo [38][39] consiste em uma generalização daquele proposto por McCulloch e Pitts e é definido conforme segue:

**Teorema 1:** O neurônio formal é um sistema dinâmico.

**Prova:** Se o neurônio é um sistema dinâmico, este deve identificar-se com as várias variáveis e funções da definição de sistema dinâmico. Considera-se “sistema dinâmico”, o seguinte objeto matemático:

$$S = \{T, U, \Omega, Y, \Gamma, X, \Phi, \lambda\} \quad (\text{Eq. 3.2})$$

onde:

- $T$  é o conjunto dos tempos;
- $\Omega$  é o conjunto das funções de entrada  $\omega \in \Omega$   

$$\Omega = \{\omega : T \rightarrow U\}$$
- $U$  é o conjunto dos valores de entrada;
- $Y$  é o conjunto dos valores de saída;
- $\Gamma$  é o conjunto das funções de saída  $\gamma \in \Gamma$   

$$\Gamma = \{\gamma : T \rightarrow Y\}$$
- $X$  é o conjunto dos estados;
- $\Phi$  é a função de transição dos estados.  $\Phi$ :  

$$T \times T \times X \times \Omega \rightarrow X$$
- $\lambda$  é a função de saída<sup>4</sup>:  $\lambda : T \times X \times U \rightarrow Y$

Identificando-se as variáveis e funções do neurônio tem-se:

<sup>4</sup> A função  $\lambda$  freqüentemente não depende de  $U$ .

$T$ , o conjunto dos tempos, é geralmente o conjunto dos inteiros;

$\Omega$ , o conjunto das funções de entrada, provenientes dos órgãos sensores ou da saída de outros neurônios;

$\Gamma$  é o conjunto das funções de saída, cujos valores são representativos das frequências de descarga dos neurônios;

$U$  é o conjunto dos valores de entrada, valores estes representativos das saídas dos órgãos sensores ou dos valores de frequências de descarga de outros neurônios;

$Y$  é o conjunto dos valores de saída, representativo da frequência de descarga do neurônio;

$X$  é o conjunto dos estados possíveis e representa a excitação do neurônio;

$\Phi$  é a função de transição dos estados  $\Phi: T \times T \times X \times \Omega \rightarrow X$  e mostra como a excitação do neurônio evolui; e

$\lambda$  é a função de saída:  $\lambda: T \times X \times U \rightarrow Y$  que, freqüentemente, é tomada como uma função cujo valor é sempre o valor de excitação do neurônio.

Tendo-se identificado todas as variáveis e funções envolvidas na definição do neurônio, pode-se afirmar, então, que o modelo de neurônio é um exemplo de sistema dinâmico.

**Nota1:** É importante observar que, muitas vezes, o modelo de neurônio é estático. Este é um caso particular de nossa definição, onde a cardinalidade do espaço de estados é um.

**Nota2:** Esta definição não inclui, como componente da entidade neurônio, o vetor de pesos de conexões entre o neurônio e os demais neurônios constituintes de uma RNA. Os pesos sinápticos fazem parte da definição de Redes Neurais Artificiais. No entanto, pode-se considerar desde já, para efeito de esclarecimentos, os pesos das conexões associadas a cada uma das entradas de um neurônio.

O neurônio formal é apresentado na Figura 3.2.

Cada entrada  $u \in U$  traz consigo um peso associado (ao nível de rede). Estas entradas podem ser saídas de outros neurônios, entradas externas à rede, uma polarização (um *bias*), ou uma combinação das anteriores. A associação de todas as entradas no instante de tempo  $t \in T$  e para o neurônio  $i$  dá origem à entrada efetiva  $net_i$ , que é representada da seguinte forma:






Figura 3.2: Neurônio Artificial.( Extraído de De Azevedo, 1997 [39])

$$net_i(t) = \sum_{j=1}^n a_{ij} \cdot y_j(t) + \sum_{k=1}^{m-1} b_{ik} \cdot u_k(t) + b_{im} \cdot bias_i \quad (\text{Eq. 3.3})$$

onde:

- $y_j(t)$  são as saídas atuais dos  $n$  neurônios conectados à entrada de  $i$ ;
- $a_{ij}$  são os pesos correspondentes às conexões entre o neurônio  $i$  e estes neurônios  $j$ ;
- $u_k(t)$  são entradas externas (não provenientes de neurônios) no instante de tempo  $t$ ;
- $b_{ik}$  são os pesos correspondentes às conexões entre o neurônio  $i$  e as  $(m-1)$  entradas externas;
- $bias_i$  é o valor de polarização para o neurônio  $i$  e
- $b_{im}$  é o peso correspondente à conexão entre o neurônio  $i$  e a polarização.

**Nota:** O *bias* é um parâmetro opcional que pode ser obtido pela simples adição de uma entrada constante (normalmente de valor unitário) e um peso apropriado.

É comum, todavia, incorporar-se a constante  $bias_i$  e as saídas  $y_j$  às entradas  $u_k$ . Os pesos correspondentes  $a_{ij}$  e  $b_{ik}$  são representados por  $w_{ij}$ , com  $j = 1$  para  $n + m$ , ou simplesmente  $j = 1$  para  $n$ . A equação fica:

$$net_i(t) = \sum_{j=1}^n w_{ij} \cdot u_j(t) \quad (\text{Eq. 3.4})$$

onde  $w_{ij}$  é um número real que sumariza a conexão sináptica entre a entrada do  $i^{\text{ésimo}}$  neurônio e a saída do  $j^{\text{ésimo}}$  neurônio.

A conexão sináptica é dita *excitatória*, se  $w_{ij} > 0$  e *inibitória*, se  $w_{ij} < 0$ .

Após a determinação de  $net_i$ , a ativação do neurônio é atualizada através da função de ativação  $\Phi$ . A saída do neurônio é produzida pela aplicação desta ativação através da função de

saída  $\lambda$ . Esta saída é correspondente à frequência de descarga do neurônio biológico. Um valor auxiliar  $\theta$  normalmente é utilizado para representar um determinado *limiar* (ou *patamar*, ou ainda *threshold*), valor abaixo do qual a saída será nula. Este limiar poderia ser substituído, também, por uma escolha apropriada da função  $\lambda$ , o que, entretanto, é mais difícil de implementar.

Note-se que as *conexões sinápticas são consideradas como externas ao modelo do neurônio*, tal como ocorre no sistema nervoso biológico e não como partes componentes do neurônio, como definido por alguns autores. Se por um lado este detalhe pode vir a ter pouca importância aparente no estudo de uma RNA em si, por outro lado proporciona a possibilidade de interpretar-se a matriz de conexões como a matriz de pesos de um grafo, o grafo representativo da rede neural, tal como sugerido por De Azevedo [38].

Apesar de o modelo apresentado ser uma generalização do modelo de McCulloch-Pitts, conforme já citado, o mesmo apresenta, entretanto, uma diferença conceitual importante: enquanto no modelo de McCulloch-Pitts o estado excitado representa a despolarização da membrana celular (ao menos aparentemente), no presente modelo fica claro que a variação da resposta do neurônio, a qual pode ser contínua entre o valor zero e um valor máximo, pode ser interpretada como a frequência de descarga do neurônio biológico [39]. Este modelo geral pode, portanto, ser utilizado perfeitamente em modelagem de processos biologicamente plausíveis.

**Nota:** Normalmente,  $net_i$  é obtido a partir do somatório das entradas. O produtório também é utilizado. Outras funções também são utilizadas, de forma muito menos freqüente, porém.

**Definição 1:** O neurônio é linear se  $\Phi$  e  $\lambda$  são funções lineares.

**Definição 2:** O neurônio é não-estacionário se as funções  $\Phi$  e/ou  $\lambda$  são funções do tempo. Neste caso, pode-se escrever:

$$x = \Phi(w_i, u_i, t) \quad \text{e} \quad y = \lambda(x, t) \quad (\text{Eq. 3.5})$$

**Definição 3:** O neurônio é dito dinâmico se, para o cálculo de  $x$  em um determinado instante, é necessário o conhecimento de  $x$  no instante anterior.

**Nota:** Por esta definição, conclui-se que o modelo de neurônio proposto por McCulloch e Pitts é um sistema dinâmico, se o retardo  $D$  não for nulo.

### A função de transição de estados $\Phi$

A função de transição de estados é função dos estados anteriores, das entradas e dos pesos sinápticos (considerando ao nível de rede). Matematicamente:

$$x(t+h) = \Phi(x(t), net(t), t, h) \quad (\text{Eq. 3.6})$$

$$y(t) = \lambda(x(t), net(t), t) \quad (\text{Eq. 3.7})$$

Ou seja, os estados futuros do neurônio são afetados pelo estado atual, bem como pelo  $net_i$ . Dado um “valor inicial”  $x(t_0)$  de uma variável de estado  $x(t)$  no tempo  $t = t_0$ , é possível prever-se os futuros valores  $x(t+h)$  de  $x(t)$ . Fazendo-se o intervalo  $h \rightarrow 0$ , o somatório torna-se uma integração, com  $x$  variando continuamente com o tempo  $t$ . A Equação 3.6 torna-se:

$$\frac{dx}{dt} = \Phi'(x, net, t) \quad (\text{Eq. 3.8})$$

### A Função de Saída $\lambda$

As funções mais comumente utilizadas como função de saída de um neurônio são: a função linear, a função logística, e a função tangente hiperbólica. Mais detalhadamente:

#### A Função Linear:

$$y(x) = ax + b \quad (\text{Eq. 3.9})$$

onde  $a$  e  $b$  são constantes escalares.

#### A Função Logística:

$$y(x) = \frac{1}{1 + e^{-kx}} \quad (\text{Eq. 3.10})$$

onde  $k$  é um escalar positivo.

Outras funções podem ser derivadas através do ajuste da constante  $k$ . Quanto maior for  $k$ , mais abrupta será a função nas proximidades de  $x = 0$ . Quando  $k \rightarrow \infty$ , a função será definida por:

$$y(x) = \begin{cases} 0 & \text{se } x < 0 \\ +1 & \text{se } x \geq 0 \end{cases} \quad (\text{Eq. 3.11})$$

A Figura 3.3 mostra as funções logísticas de ativação para  $k = 0,5; 1; 2; 4; 8$ .






Figura 3.3: Funções de ativação unipolares. ( Extraído de De Azevedo, 1997 [39])

### A Função Tangente Hiperbólica:

É a função bipolar *sigmóide* mais utilizada:

$$y(x) = \tanh(kx) = \frac{e^{kx} - e^{-kx}}{e^{kx} + e^{-kx}} \quad (\text{Eq. 3.12})$$

onde  $k$  é um escalar positivo.

Novamente outras funções podem ser derivadas pelo ajuste da constante  $k$ . Quanto maior for  $k$ , mais abrupta será a função nas proximidades de  $x = 0$ . A Figura 3.4 ilustra a função tangente hiperbólica para  $k = 0,5; 1; 2; 4; 8$ .




Figura 3.4: Funções de ativação bipolares. ( Extraído de De Azevedo, 1997 [39])

Se  $k \rightarrow \infty$ , a tangente hiperbólica torna-se a função  $\text{sgn}(x)$ , ou “*sigmóide*”, a qual é definida por (Figura 3.5):

$$y(x) = \begin{cases} -1 & \text{se } x < 0 \\ +1 & \text{se } x \geq 0 \end{cases} \quad (\text{Eq. 3.13})$$




Figura 3.5: Função de ativação sigmóide “hard limit”.

A princípio, qualquer função monotonicamente crescente e contínua, tal que  $x \in \mathcal{R}$  e  $y(x) \in [-1,1]$ , pode ser empregada na modelagem neural. No entanto, as funções definidas pelas equações 3.9, 3.10 e 3.12 oferecem a vantagem de serem *diferenciáveis*, o que torna possível aplicar-se operadores gradiente que agilizam os algoritmos de treinamento.

### Topologias das RNAs

A abordagem utilizada neste trabalho para definir-se Redes Neurais Artificiais segue também a proposta de De Azevedo [39], qual seja:

Pode-se afirmar que as Redes Neurais Artificiais sejam *sistemas dinâmicos complexos* definidos por:

**Definição 4:** *Um sistema dinâmico complexo é uma rede de sistemas interconectados.*

Um sistema dinâmico complexo pode ser representado por um *grafo direcionado*, ou *dígrafo*, onde os “vértices” representam os sistemas componentes (ou subsistemas) e os “arcos”, as interações entre os subsistemas. Para definir grafos, arcos e vértices, deve-se lançar mão de conceitos de Teoria de Grafos, baseados nos estudos de Harary [64] e Aho [1]:

**Definição 5:** *Um Grafo  $G$  consiste em um conjunto não-vazio finito de vértices  $V = v_i$ , juntamente com um conjunto não ordenado de arcos  $A$ , os quais conectam certos pares de vértices. Cada par  $v_i, v_j$  de vértices em  $V$  é um arco de  $G$  e o par  $v_i, v_j$  é dito “juntar”  $v_i$  e  $v_j$ .*

**Definição 6:** *Um Grafo  $G$  é Rotulado quando os  $p$  vértices são distinguíveis uns dos outros por nomes ou “rótulos”.*

**Definição 7:** Um Grafo  $G$  é Arco Rotulado quando também os arcos são distinguíveis uns dos outros por nomes ou “rótulos”.

Em tendo sido estabelecido o significado de “Grafo” em nosso contexto, podemos agora definir as Redes Neurais Artificiais.

**Definição 8:** Uma Rede Neural Artificial, RNA, é um Sistema Dinâmico Complexo representado por um grafo arco rotulado, onde cada vértice é um Neurônio Artificial, NA.

Neste caso, os rótulos são, naturalmente, valores numéricos e correspondem aos valores das conexões entre os diferentes neurônios. Podemos também definir diferentes tipos de redes, tais como:

**Definição 9:** Uma Rede Neural Contínua no Tempo é uma rede neural definida em um subconjunto contínuo do eixo do tempo  $T = \mathfrak{R}$ .

**Definição 10:** Uma Rede Neural Discreta no Tempo é uma rede neural definida em um subconjunto discreto do eixo do tempo  $T = \mathbb{Z}$ .

Informalmente, pode-se dizer que uma RNA consiste em um sistema composto por vários neurônios, de modo que as propriedades de sistema possam ser empregadas. Os neurônios estão interligados entre si por *conexões sinápticas* (tal como no sistema neuronal biológico). Parte destes neurônios sofrem excitações externas, formam a *camada de entrada da rede* e são denominados de *neurônios de entrada*. No contexto biológico, estes neurônios correspondem às células nervosas dos órgãos dos sentidos. Outra parte dos neurônios da rede têm suas respostas utilizadas para alterar, de alguma forma, o mundo exterior; formam a *camada de saída da rede* e são denominados *neurônios de saída*. São os *motoneurônios*, ou *neurônios motores*, que excitam os tecidos musculares nos sistemas biológicos. O último grupo de neurônios são os chamados *neurônios internos* à rede ou neurônios *hidden* e compõem a camada ou as camadas “ocultas” da rede. Estes últimos são os responsáveis pela ligação entre as camadas de entrada e de saída da rede e pelo processamento, propriamente dito, que a rede realizará sobre a entrada, para dar origem à saída ou resposta da rede.



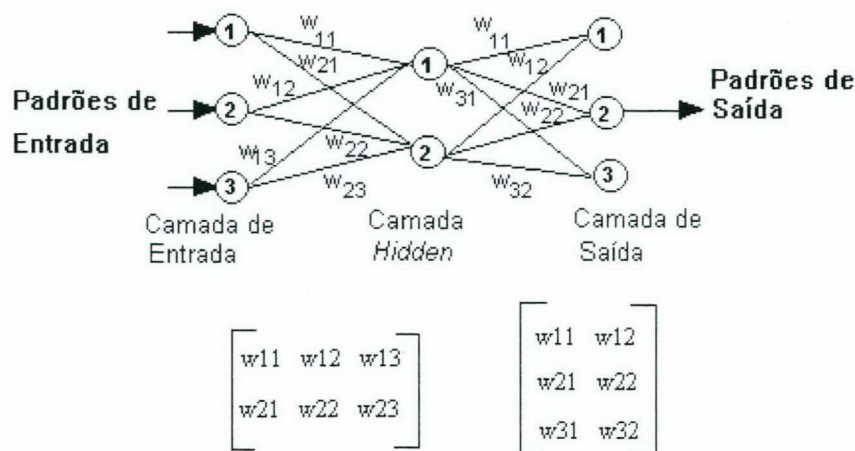


Figura 3.6: Arquitetura de Rede Neural Artificial - a *Feedforward*. ( Extraído de De Azevedo, 1997 [39])

A rede ilustrada na Figura 3.6 é apenas uma das formas possíveis de RNA e nesta apenas a topologia da rede está representada. Para a caracterização completa de uma RNA é necessário que sejam especificados os seguintes elementos:

- *Neurônios*: os componentes da rede. Se todos os neurônios da rede forem do mesmo tipo a rede é dita *homogênea*. Se os neurônios forem diferentes, a rede será chamada de *heterogênea*.

- *Respostas dos neurônios*. Seja:

$U$  o vetor de entradas da RNA (sinal excitador de cada neurônio de entrada);

$Y$  o vetor de respostas da RNA (sinal de saída global) e

$O$  o vetor de respostas dos neurônios da rede.

Se a dimensão da camada de entrada é  $m$ , a da camada de saída é  $p$  e a rede tem  $n$  neurônios, pode-se concluir que:

- a dimensão de  $U$  é igual a  $m$ ;
- a dimensão de  $Y$  é igual a  $p$ ;
- a dimensão de  $O$  é igual a  $n$ ;
- em uma rede onde todos os neurônios influenciam e são, ao mesmo tempo, influenciados pelo meio ambiente:  $n = m = p$ ;
- se  $m + p < n$ , significa que existem neurônios internos (e uma ou mais camadas internas) na rede.

- *Ativação global da rede*: Denomina-se *Estado* ou *Padrão de Ativação Global da RNA* o vetor  $\in \mathbb{R}^n$ , onde  $n$  é o número de neurônios da rede, composto pelos estados de ativações

individuais dos neurônios da rede, em um dado instante  $t$ . Este padrão de ativação pode ser visto como uma metáfora do “pensamento” da rede, em um determinado momento.

- *Padrão de Conectividade*: define como os neurônios estão conectados. Este padrão pode ser representado através de uma *matriz de conectividade*  $W$ , de dimensão  $n \times n$ , se a rede for composta de  $n$  neurônios. O elemento  $w_{ij} \in W$  será positivo se a conexão, a sinapse, entre os neurônios  $i$  e  $j$  for excitatória e negativo, se a sinapse for inibitória.

- *Propagação da atividade da rede*: Em uma rede na qual os neurônios são sistemas a tempo contínuo, o modelo do neurônio é uma equação diferencial e a atividade da rede se propaga segundo a solução de um conjunto de equações diferenciais simultâneas. No caso onde os neurônios são representados por equações a diferenças finitas, que é o caso mais freqüente, a propagação da atividade da rede pode ser de dois tipos: *síncrona* e *assíncrona*. Na propagação síncrona a ativação de todos os neurônios é atualizada ao mesmo tempo, de forma sincronizada, através de um relógio. Na propagação assíncrona, os neurônios têm suas excitações atualizadas em determinados momentos distintos, independentemente dos outros neurônios da rede.

- *Desenvolvimento da matriz de conectividade*: Deve ser estabelecida a maneira pela qual se chegará a uma matriz de conectividade definitiva e eficiente para a resolução de um problema específico. Freqüentemente esta matriz é encontrada através de um mecanismo (um algoritmo, por exemplo) de *aprendizado*, no qual a rede ajusta-se iterativamente para representar um certo conjunto de conhecimento. Esta não é a única maneira, entretanto e pode-se, inclusive, associar diretamente os elementos de conhecimento aos valores das conexões. O *Aprendizado* ou *Treinamento* da rede pode ser *Supervisionado*, quando um operador “instrui” a rede sobre a forma pela qual esta deverá representar o conjunto de conhecimento, ou *Não-Supervisionado*, quando a própria rede consegue “intuir”, extrapolar, fazer emergir de si mesma as relações, a representação para o conjunto de conhecimento.

- *O ambiente externo*: é o que define o uso da rede. Por exemplo, se o objetivo da utilização de uma RNA é controlar um processo, tem-se a rede aplicada ao controle e o processo será o ambiente no qual será implementada a rede. Se o objetivo for reconhecimento de caracteres, o ambiente será o conjunto de caracteres que podem ser apresentados à rede para classificação e assim por diante.

- *Representação do conhecimento na rede*: O conhecimento na rede pode ser representado de forma *localizada* ou *distribuída*. O conhecimento é localizado quando a um neurônio, ou a uma sinapse, corresponde um conhecimento determinado, e é distribuído quando a cada conhecimento corresponde um grupo de neurônios ou de sinapses. Considere-se, por exemplo,



que se queira representar uma letra do código ASCII na entrada de uma rede. Existem duas opções básicas:

Utilizar-se 256 neurônios na camada de entrada e fazer corresponder a cada neurônio uma letra, um código. Neste caso, apresentar-se uma letra à rede significa ativar-se apenas o neurônio correspondente e manter os outros inativos;

Utilizar-se 8 neurônios que correspondam à representação binária do código ASCII da letra; um neurônio ativo para cada bit '1', por exemplo.

Pode-se notar que a representação distribuída é muito mais econômica que a localizada.

A questão mais controversa em se utilizar RNAs é que não existem métodos para determinação destes elementos de caracterização *ótimos*. Ou seja, qualquer escolha feita durante o projeto de uma rede neural é feita à base de heurísticas ou empirismos. No entanto, as RNAs têm demonstrado notáveis desempenhos e aplicabilidade, em uma gama muito grande de áreas do conhecimento, à revelia desta ausência de justificativas matemáticas e considerações mais apuradas.

A seguir será descrito o modelo de RNA utilizado neste trabalho:

### 3.1.3 Rede Feedforward com algoritmo de treinamento Backpropagation

A rede tipo *Feedforward*, ou *Direta*, ou ainda "*Perceptron Multicamada*"<sup>5</sup> (Figura 3.7) [86][78][44], que utiliza o algoritmo de treinamento supervisionado *Backpropagation*, transformou-se em sinônimo de Rede Neural Artificial, em sistemas que utilizam o Paradigma Conexionista, devido principalmente à facilidade de implementação da mesma e à disponibilidade de ampla bibliografia de referência e de *softwares* aplicativos para implementação de tais redes.

O treinamento *Backpropagation* da *Feedforward* exige que seja definido um *conjunto de treinamento*, onde todas as classes (ou grande parte destas) estejam representadas. E paralelamente, deve-se definir um *conjunto target (alvo)* que correlacione adequadamente cada entrada representativa de uma classe (cada *vetor de treinamento*) com a saída desejada correspondente (*vetor de saída target*). Ou seja, como os pares de vetores que definem as classes de entrada e o correspondente espaço de saída devem ser definidos *a priori*, o treinamento é dito *Supervisionado*.

---

<sup>5</sup> Minsky e Papert provaram em seu livro *Perceptrons* [95], que esta rede, tal como foi criada por Rosenblatt em 1957 [116] – composta de uma única camada de processamento, somente seria capaz de solucionar problemas linearmente separáveis.




Figura 3.7: Rede Neural Direta com 1 camada interna mais as camadas de entrada e de saída, completamente conectada. Cada neurônio, nas camadas interna e de saída da rede, é composto de um somatório ponderado *net* das entradas dos neurônios da camada anterior (e do *bias*, se houver) seguido de uma função de transição de estados  $\phi$  e de uma função de saída  $\lambda$ .

A partir de um conjunto de treinamento adequado (em termos de representatividade e tamanho), de uma topologia adequada (o número de neurônios da rede e o número de camadas da mesma influenciam diretamente seu desempenho), e da aplicação de um algoritmo de treinamento com *parâmetros de treinamento* satisfatoriamente ajustados, espera-se que a rede seja treinada e que se torne capaz de “reconhecer” e classificar não só os vetores utilizados em seu treinamento, com um erro mínimo, mas também de generalizar e classificar novos padrões apresentados.

O Capítulo 5 apresentará a topologia de Rede Neural Artificial utilizada na implementação do SIDAPE e o Capítulo 7 levantará sucintamente as razões que levaram a esta escolha.



## 3.2 Transformadas de Sinais

As Ferramentas de processamento de sinais que serão explanadas nas seções seguintes referem-se àquela classe de ferramentas que manipulam características de tempo, frequência e fase do sinal para proporcionar uma análise mais fácil e eficiente. Será assumido que o sinal a ser analisado já foi digitalizado, pois o processamento será feito em computador. As ferramentas de transformação, a princípio, são aplicáveis apenas a sinais periódicos e aperiódicos, mas o sinal de EEG, apesar de não ser periódico, apresenta uma certa *periodicidade de padrões*, se observado em intervalos de tempo de tamanho determinado, o que o habilita para sofrer este tipo de análise.

### 3.2.1 As Transformadas

A Transformada de um sinal  $f(t)$  não-periódico consiste em um operador matemático linear, aplicado à função, que *decompõe* este sinal como sendo o somatório (neste caso, um somatório de elementos infinitesimalmente próximos entre si, ou uma *integral*) de outras funções periódicas. Desta forma, pode-se dizer que a Transformada é uma forma de *representação de sinais*, em termos de outros sinais mais simples matematicamente e normalmente periódicos.

Uma Transformada também é utilizada quando se deseja ressaltar alguma característica específica do sinal que seja presente ou mais evidente nos sinais de representação.

De modo geral, a Transformada<sup>6</sup>  $T$  de um sinal  $f(t)$  pode ser expressa através da equação :

$$T(\omega) = \int_{-\infty}^{+\infty} f(t) \cdot \text{Kernel}(\omega, t) \cdot dt \quad (\text{Eq. 3.14})$$

onde  $\omega = 2\pi f$  e  $\text{Kernel}(\omega, t)$  é a função de representação periódica, de frequência de oscilação  $\omega$ , que forma a base *ortonormal*<sup>7</sup> [140][105][27] para a decomposição de  $f(t)$  e também define o tipo de Transformada que será aplicado.

<sup>6</sup> Neste trabalho, qualquer referência a *Transformadas* subentende tratar-se de *Transformadas Integrais*.

<sup>7</sup> “Se  $H$  é um espaço de produto interno completo, podemos afirmar que uma coleção  $\{\phi_n: n \in \mathbf{Z}\}$  é uma *base ortonormal*, ou *Base de Hilbert* para  $H$  se as seguintes condições forem satisfeitas:

- *Ortogonalidade*: Se  $n, m \in \mathbf{Z}$  e  $n \neq m$ , então  $\langle \phi_n, \phi_m \rangle = 0$ ;
- *Normalização*: Para cada  $n \in \mathbf{Z}$ ,  $\|\phi_n\| = 1$ ;
- *Totalidade*: Se  $f \in H$  e  $\langle f, \phi_n \rangle = 0$  para todo  $n \in \mathbf{Z}$ , então  $f = 0$  [140]”.

### 3.2.2 A Transformada de Fourier de Curto Termo - STFT

A Transformada de Fourier [140][27][105][15] tem sido bastante utilizada em processamento de sinais, inclusive os bioelétricos. Porém, apesar de fornecer uma estimativa excelente do conteúdo de frequências de um sinal, não traz nenhuma informação sobre como estão distribuídas estas frequências *no tempo*! Em sinais estacionários, isto é, cujo comportamento não varia no tempo, isto não representa um problema, mas em sinais não-estacionários (também ditos *variantes no tempo*) ou sinais que eventualmente apresentem *transientes*, como sinais de EEG, ECG ou da fala, o conjunto de componentes de frequências do instante de tempo atual não necessariamente é o mesmo em instantes de tempo anteriores, nem em posteriores. Em outras palavras, a Transformada de Fourier não fornece informações sobre a evolução no tempo das características espectrais do sinal. Se a Transformada de Fourier for calculada sobre todo o intervalo de tempo para o qual o sinal foi definido estes conjuntos diferenciados de componentes de frequência confundir-se-ão em um único espectro de magnitudes ou potências de frequências, sem qualquer relação com os tempos em que ocorreram (Figura 3.8 e Figura 3.9).




Figura 3.8: Dois sinais diferentes no tempo, mas com iguais composições em frequência e com eventos transitórios ocorrendo em momentos diferentes, geram espectros de magnitude de frequência idênticos.

A solução mais óbvia, portanto, seria particionar-se este intervalo completo de tempo em subintervalos menores, as *épocas* ou *janelas de tempo deslizantes*<sup>8</sup>, nas quais os conteúdos de frequência fossem “mais ou menos” constantes (onde o sinal pode ser considerado como “quase-estacionário”).

<sup>8</sup> Estas janelas são chamadas de “deslizantes” porque se deslocam no tempo sobre o sinal a ser analisado e então ocorre a convolução em frequência desta janela finita com o sinal, naquele intervalo determinado de tempo.




Figura 3.9: Sinal não-estacionário acima e sinal estacionário abaixo: diferentes no tempo, mas com iguais composições em frequência geram espectros de magnitudes de frequência idênticos.

A Transformada de Fourier, então, é calculada para cada época individual e fornece o espectro de frequências para aquele intervalo específico de tempo. Este procedimento é denominado de *Transformada de Fourier de Curto Termo* - sigla STFT, em inglês - e foi desenvolvido por Gabor [51], em 1940. A STFT é definida matematicamente por:

$$\text{STFT}_{\omega, \tau} [f(t)] = \int_{-\infty}^{+\infty} f(t) \cdot g^*(t - \tau) \cdot e^{-j\omega t} \cdot dt \quad (\text{Eq. 3.15})$$

onde:

- $f(t)$  – é o sinal discreto no tempo a ser transformado,
- $g(t - \tau)$  – é a janela de tempo, ou época, atrasada de  $\tau$  no tempo ( $g^*(t)$  é o complexo conjugado da janela  $g(t)$ ) e
- $\omega$  – é a frequência angular, igual a  $2\pi f$ .

Cada valor de  $\tau$  na STFT, portanto, corresponde à Transformada de Fourier de um segmento do sinal  $f(t)$ , centrado em  $t = \tau$ , e é uma operação linear. A Figura 3.10 ilustra a análise de um sinal não-estacionário utilizando-se a representação tempo-frequência.



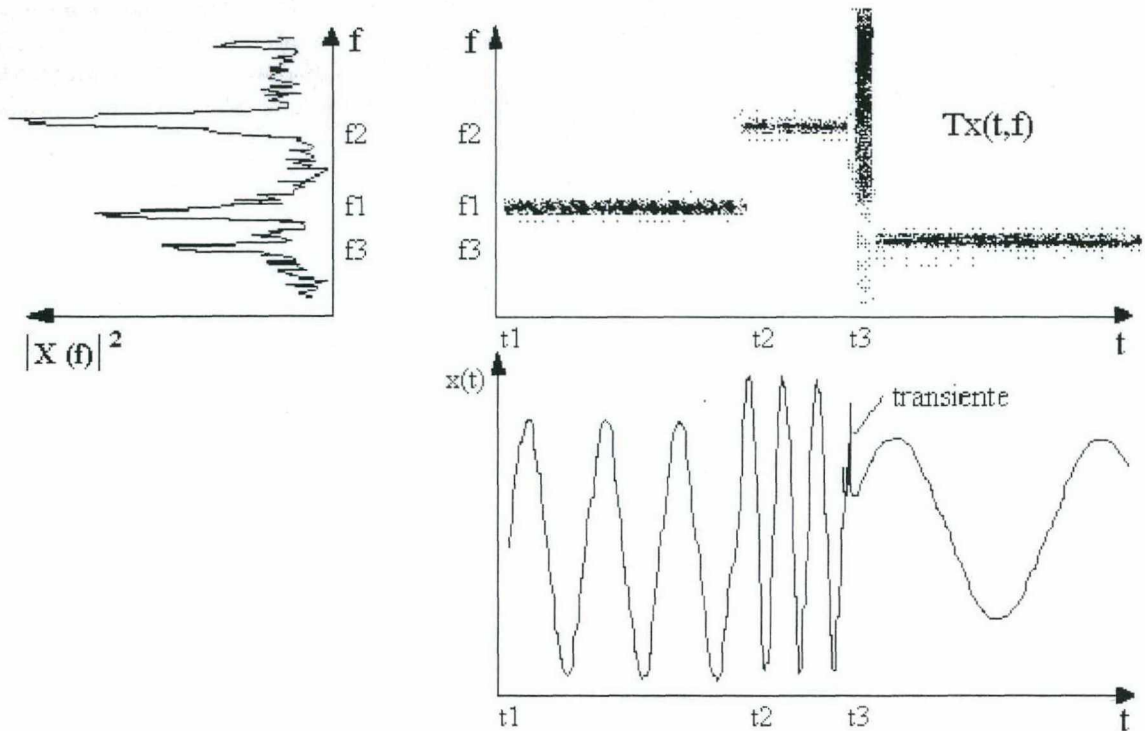


Figura 3.10: Representação tempo-frequência de um sinal que consiste de três senoidais consecutivas de frequências  $f_1, f_2, f_3$ , respectivamente e um transiente ocorrido no instante  $t_3$ . O sinal correspondente no domínio do tempo,  $x(t)$ , é mostrado abaixo.  $T_x(t,f)$  é mostrado no alto e o espectro de Fourier é mostrado horizontalmente, à esquerda. (Modificado de *The Transforms and Applications Handbook* [121]).

A questão mais difícil na análise por STFT é justamente definir-se o *tamanho da janela de tempo*. Se a janela for suficientemente pequena para assegurar que componentes muito rápidas ou transientes de um sinal sejam discriminados das demais (*resolução no tempo*) vai gerar uma banda passante de frequência mais larga (devido às descontinuidades bruscas da janela de tempo pequena, que adiciona componentes de altas frequências extras) o que prejudica a *resolução em frequência*. Se a janela no tempo for suficientemente larga para captar todas as componentes de frequência de uma época, em frequências muito baixas por exemplo, a resolução em frequência estará assegurada, mas a resolução em tempo diminuirá. A relação fixa entre as resoluções no tempo,  $\Delta t$ , e em frequência,  $\Delta f$ , é determinada pelo *princípio da incerteza*, ou *Desigualdade de Heisenberg* [75][121]:

$$\Delta t \cdot \Delta f \geq \frac{1}{4\pi} \quad (\text{Eq. 3.16})$$

Por estas razões, o projetista deverá sempre optar por um valor de largura de janela  $\Delta t$ , segundo a resolução que deseja priorizar, já que não é possível obter-se ambas as resoluções, em níveis satisfatórios, simultaneamente. Uma vez que tenha sido fixado um valor para  $\Delta t$  obtém-se também o valor de  $\Delta \omega = \Delta f \cdot 2\pi$ , através da Desigualdade de Heisenberg, e pode-se traçar uma representação gráfica para a STFT, chamada *Espectrograma* (Figura 3.11).




Figura 3.11: Cobertura do espaço tempo-frequência da STFT, onde  $\Delta\omega$  e  $\Delta t$  são fixos para todo o plano - Espectrograma (Modificado de *The Transforms and Applications Handbook* [121]).

A função que geralmente é empregada como janela  $g(t)$  foi proposta pelo próprio Gabor [51] e é a chamada “Gaussiana”, a qual é definida por:

$$g(t) = \frac{1}{a} e^{-\frac{\pi t^2}{a^2}} \quad \text{e} \quad (\text{Eq. 3.17})$$

$$G(\omega) = \frac{1}{\sqrt{\pi}} e^{-\frac{a^2 \omega^2}{4\pi}} \quad (\text{Eq. 3.18})$$

### 3.2.3 A Transformada Wavelet - WT

Como visto na seção anterior, a STFT permite que se tenha noção da evolução do espectro de frequências do sinal ao longo do tempo, porém constatou-se também a deficiência desta ferramenta em fornecer uma boa resolução simultânea em tempo e em frequência.

Um tipo de análise matemática alternativa foi desenvolvida e formalizada em 1984 por Grossmann e Morlet com o nome de *Ondelettes* [20] e atualmente é mais conhecida como *Transformada Wavelet* (WT).

Da mesma forma que a STFT e a *Distribuição de Wigner* [141], a *Transformada Wavelet* consiste em um tipo de representação tempo-frequência de um sinal. A principal diferença entre a Transformada STFT e a *Wavelet* é que a última dispensa o conceito de janela de tempo de tamanho fixo [77], para permitir boas resoluções em tempo e frequência (Figura 3.12). Para isto, a Transformada *Wavelet* utiliza um conjunto de funções ortogonais de janelamento, as *funções wavelet*, com larguras variadas. Deve-se definir uma função *wavelet* básica, a *wavelet-mãe*, a partir da qual todas as outras serão derivadas através dos processos de *Dilatação* ou *Escalaonamento* e *Translação*:






Figura 3.12: Representação dos filtros passa-banda (transformadas de Fourier das funções janela de tempo) da STFT e da WT no domínio da frequência.

**Definição 1:** Chama-se *Dilatação* de um fator  $a$ , com  $a > 0$ , ao operador  $\sigma_a$  de “estiramento” de uma função  $f(t)$  em um domínio  $a$  vezes mais longo:

$$[\sigma_a f](t) = \frac{1}{\sqrt{a}} f\left(\frac{t}{a}\right) \quad (\text{Eq. 3.19})$$

**Definição 2:** Chama-se *Translação* de um fator  $\tau$ , ao operador  $\varphi_\tau$  de “atraso” de uma função  $f(t)$  no domínio do tempo  $t$ :

$$[\varphi_\tau f](t) = f(t - \tau) \quad (\text{Eq. 3.20})$$

Portanto, a base da Transformada *Wavelet* não é mais formada por senoidais ortogonais de Fourier, mas sim um conjunto arbitrário de versões dilatadas (ou comprimidas) e transladadas no tempo de uma função básica conveniente, que atende normalmente certas premissas, como será visto na próxima seção. Assim, a *Transformada Wavelet Contínua* - CWT pode agora ser definida como [20][121][134][135]:

$$\text{CWT}_{a,\tau}[f(t)] = \int_{-\infty}^{+\infty} f(t) \cdot \psi_{a,\tau}^*(t) \cdot dt \quad (\text{Eq. 3.21})$$

onde:

- $f(t)$  – é o sinal discreto no tempo a ser transformado;
- $\psi^*(t)$  – é o complexo conjugado da *wavelet-mãe*  $\psi(t)$ . A função  $\psi(t)$  é a janela de tempo, a partir da qual as outras funções são obtidas, por meio de translações e dilatações:

$$\psi_{a,\tau}(t) = \frac{1}{\sqrt{a}} \cdot \psi\left(\frac{t - \tau}{a}\right) \quad (\text{Eq. 3.22})$$

- $a^{-1/2}$  – é a constante de normalização da energia para as *wavelets*;
- $\tau$  – é o fator de translação e
- $a$  – é o fator de dilatação não-nulo. Se  $a > 1$  a função *wavelet* é expandida e se  $a < 1$ , a *wavelet* é contraída.

No domínio da frequência, as *wavelets* são escalonadas por  $1/a$  e possuem amplitudes proporcionais a  $a^{1/2}$ . No domínio do tempo, as amplitudes das *wavelets* são proporcionais a  $a^{-1/2}$ . Pode-se notar que a Transformada *Wavelet* transforma uma função dependente de apenas uma variável em uma função de duas variáveis. Esta representação por CWT é redundante e a transformada *wavelet* inversa nem sempre é única [20].

### A Base da Transformada Wavelet

Ao contrário da Transformada de Fourier e das outras transformadas, a base da CWT não é especificada em sua definição. O projetista poderá escolher sua base, ortogonal ou não, ou mesmo criá-la para uma dada aplicação específica [25][110]. As condições observadas para investigar-se a utilização de uma determinada base como Conjunto *Wavelet* são [121]:

- Condição de *Admissibilidade* – estabelece que a função *wavelet* deve satisfazer a seguinte condição [121]:

$$C_n = \int \frac{|\Psi(\omega)|^2}{|\omega|} \cdot d\omega < +\infty \quad (\text{Eq. 3.23})$$

a qual indica que a função candidata a *wavelet* deve *oscilar*, isto é, possuir valor médio nulo:

$$\bar{\psi}(t) = \int_{-\infty}^{+\infty} \psi(t) \cdot dt = 0 \quad (\text{Eq. 3.24})$$

A Equação 3.24 também mostra que as *wavelets* não podem possuir componentes na frequência zero e portanto são, por definição, *filtros passa-banda* (Figura 3.13) [121]. Se a condição de Admissibilidade for satisfeita, significa que a WT admite uma *inversa*;

- Condição de *Conservação da Energia* – é a equivalente ao Teorema de Parseval, da Transformada de Fourier, para a CWT e é definida por:

$$\text{Energia de } \psi(t) = \int_{-\infty}^{+\infty} |\psi(t)|^2 \cdot dt = \text{constante} \quad (\text{Eq. 3.25})$$




Figura 3.13: Algumas *wavelets* simétricas em várias escalas e locações. Os pares  $(a, \tau)$  que marcam cada forma de onda denotam a escala e a translação, respectivamente. A figura (A) mostra o domínio do tempo, e (B), as *wavelets* representadas no domínio da frequência. (Modificado de [44])

- Condição de *Regularidade* – as *wavelets* devem possuir decaimento exponencial, tal que seus momentos das  $n+1$  primeiras ordens sejam iguais a zero [121]. O momento  $M_p$  de decaimento de uma função  $\psi(t)$  é definido por:

$$M_p = \int t^p \cdot \psi(t) \cdot dt \quad \text{para } p = 0, 1, 2, \dots \quad (\text{Eq. 3.26})$$

A velocidade de convergência para zero dos coeficientes de uma CWT, com o decréscimo de  $a$ , é determinada pelo primeiro momento não-nulo da *wavelet* básica  $\psi(t)$ . Se os primeiros  $n+1$  momentos forem iguais a zero ( $M_p = 0$ , para  $p = 0, 1, 2; \dots, n$ ), significa que os coeficientes da transformada *wavelet* para a função  $\psi(t)$  decairão rapidamente (proporcionalmente a  $a^{n+2}$ ) com o decréscimo de  $a$ , levando a uma satisfatória *concentração*<sup>9</sup> nos domínios do tempo e da frequência [121].

- *Simetria* – é desejável que as funções *wavelet* sejam simétricas com relação ao eixo  $y$  (funções pares) para aumentar as propriedades ortogonais e possibilitar uma transformada inversa menos redundante.

Ou seja, as *wavelets*, tipicamente, são funções pares oscilatórias atenuadas exponencialmente até a amplitude zero nas extremidades [121] e com larguras e amplitudes variadas. É comum porém, que funções *wavelet* não satisfaçam todas as condições citadas acima.

<sup>9</sup> A propriedade de uma função que seja zero, fora de um dado intervalo de tempo finito é denominada de *suporte compacto*. Ou seja, funções *wavelet* com capacidades de concentrar a energia de um sinal em um intervalo finito são chamadas de *funções suportadas compactamente*.



### Exemplos de Funções Wavelet

Existe um grupo crescente de funções utilizadas como bases *wavelet* por suas características convenientes. Uma das janelas mais utilizadas em WT é a Gaussiana, também utilizada em outros tipos de transformadas, nas quais, porém, possui largura fixa e é denominada de *Função de Gabor*. A Gaussiana é tão utilizada porque sua transformada também tem comportamento gaussiano (vide Equação 3.18), o que implica em pequeno espalhamento do espectro de frequências (tem o valor mínimo  $\Delta t \cdot \Delta f = 1/4\pi$ ).

A função Gaussiana foi utilizada como *wavelet* pela primeira vez, por Martinet, Morlet e Grossman [92], em análise de padrões de sinais sonoros [121] e atualmente é conhecida como *Base de Morlet*, quando aplicada à Transformada *Wavelet*. A função *wavelet* de Morlet básica é, na verdade, a multiplicação da base de Fourier pela janela Gaussiana:

$$\psi(t) = e^{j\omega_0 t} \cdot e^{-\frac{t^2}{2}} \quad (\text{Eq. 3.27})$$

e a sua Transformada de Fourier é:

$$\Psi(\omega) = \sqrt{\frac{\pi}{2}} \left\{ e^{-\left[\frac{(\omega - \omega_0)^2}{2}\right]} + e^{-\left[\frac{(\omega + \omega_0)^2}{2}\right]} \right\} \quad (\text{Eq. 3.28})$$

A Figura 3.14 ilustra a diferença da utilização da Gaussiana na Transformada de Gabor, como Base de Gabor (Figura 3.14(a)) e na WT, como Base de Morlet (Figura 3.14(b)).

A Base de Morlet não atende completamente à Condição de Admissibilidade porque  $\Psi(0)_{\text{Morlet}} \neq 0$  e portanto  $C_n = +\infty$ . Porém, se  $\omega_0$  é suficientemente grande o valor de  $\Psi(0)$  torna-se muito próximo de zero (p.e.,  $\omega_0 = 5 \Rightarrow \Psi(0) \cong 10^{-6} \cong 0$ , para muitos computadores).

Gabor propôs também sua versão para utilização da Gaussiana como função *wavelet*, na forma de sua derivada de segunda ordem:

$$\psi(t) = (1 - t^2) \cdot e^{-\frac{t^2}{2}} \quad \text{e} \quad \Psi(\omega) = -\omega^2 \cdot e^{-\frac{\omega^2}{2}} \quad (\text{Eq. 3.29})$$

a qual denominou de *Wavelet Chapéu-Mexicano*, devido ao seu formato [121]. A grande vantagem da *wavelet* de Gabor é que a mesma é real, par (Figura 3.15) e satisfaz a condição de admissibilidade [121].




Figura 3.14: Funções Gaussianas em: (a) Base de Gabor e (b) Base *Wavelet* de Morlet, com  $a = 2^m$  e  $\tau = ns$ , para diferentes  $m$ . Em (c), a representação tempo-frequência da Transformada de Gabor e tempo-escala da WT para uma função degrau  $f(t)$ . (Modificado de *The Transforms and Applications Handbook* [121]).




Figura 3.15: *Wavelet* "Chapéu-Mexicano"  $\psi(t)$  e sua Transformada de Fourier  $\Psi(\omega)$ . (Modificado de *The Transforms and Applications Handbook* [121]).



Outra função muito utilizada é *Wavelet* de Haar (Figura 3.16), introduzida por Haar em 1910 [62] e definida como [121][134][13][135][20]:

$$\psi(t) = \begin{cases} 1 & \text{se } 0 < t < 1/2 \\ -1 & \text{se } 1/2 \leq t < 1 \\ 0 & \text{caso contrário} \end{cases} \quad (\text{Eq. 3.30})$$

Para fins práticos, a *Wavelet* de Haar pode ser reescrita como o resultado de uma convolução entre a função retangular  $\text{rect}(2t)$  e duas funções impulso<sup>10</sup>, ou  $\delta(t)$  (também conhecida por *função de Dirac*):

$$\psi(t) = \text{rect}\left[2\left(t - \frac{1}{4}\right)\right] - \text{rect}\left[2\left(t - \frac{3}{4}\right)\right] = \text{rect}(2t) \cdot \left[\delta\left(t - \frac{1}{4}\right) - \delta\left(t - \frac{3}{4}\right)\right] \quad (\text{Eq. 3.31})$$

A *wavelet* de Haar é uma função real, não-simétrica com respeito a  $t = 1/2$  e satisfaz a condição de admissibilidade. A transformada de Fourier é dada por:

$$\Psi(\omega) = 4j \cdot e\left(-j\frac{\omega}{2}\right) \cdot \frac{1 - \cos\frac{\omega}{2}}{\omega} \quad (\text{Eq. 3.32})$$

cuja amplitude  $|\Psi(\omega)|$  é par e simétrica para  $\omega = 0$  (Figura 3.16) [121].

A *Wavelet* de Haar, por ser descontínua no tempo, gera valores de amplitude altos quando ocorrerem *descontinuidades* no sinal, como no caso dos transientes das séries temporais.




Figura 3.16: *Wavelet* básica de Haar  $\psi(t)$  e sua Transformada de Fourier  $\Psi(\omega)$ . (Modificado de *The Transforms and Applications Handbook* [121].

A maior desvantagem no emprego deste tipo de base, porém, é que Haar não satisfaz a condição de regularidade, já que seu momento de primeira ordem é não-nulo. O espectro de Fourier da *Wavelet* Haar converge muito lentamente para zero, com o aumento de  $1/\omega$  e este decaimento é da ordem de  $(1/a)^{-3/2}$ .

A base Haar constitui, portanto, a base ortonormal mais simples que existe, porém oferece uma fraca localização em frequência, em comparação com as demais *wavelets*.

<sup>10</sup> As funções retangular e impulso são definidas por:  $\text{rect}(t) = \begin{cases} 1 & \text{se } -1/2 < t < 1/2 \\ 0 & \text{caso contrário} \end{cases}$  e  $\delta_n(t) = \begin{cases} 1 & \text{se } t = n \\ 0 & \text{caso contrário} \end{cases}$ .

Um quarto tipo de base *Wavelet* mais sofisticada e de maior aplicabilidade, citado por Bourges-Sévenier [20], é o conjunto de bases de *Daubechies*. Estas são uma família de *wavelets* ortonormais que possuem a máxima regularidade e não são fornecidas na forma analítica. A Figura 3.17 ilustra as funções de escala  $\phi(t)$  (as quais serão apresentadas na seção 3.2.4, que trata da Transformada *Wavelet* Discreta) e funções *wavelet*  $\psi(t)$  de Daubechies para  $D=2,3,\dots,7$  (a função de Daubechies  $D=1$  é igual à função de Haar).

Existem diversas funções e famílias de funções *Wavelet* e sempre estão sendo criadas outras, dependendo da aplicação a que se destinam [25][110]. A Figura 3.18 ilustra membros de algumas das famílias mais conhecidas, atualmente.

A partir do Capítulo 5 ficará claro que a escolha do tipo de base a ser aplicada em uma transformação *Wavelet* influencia substancialmente os resultados obtidos neste processo [119]. E o presente trabalho baseou-se exatamente nesta premissa para adequar o uso da Transformada *Wavelet* à detecção de espículas em sinais de EEG.

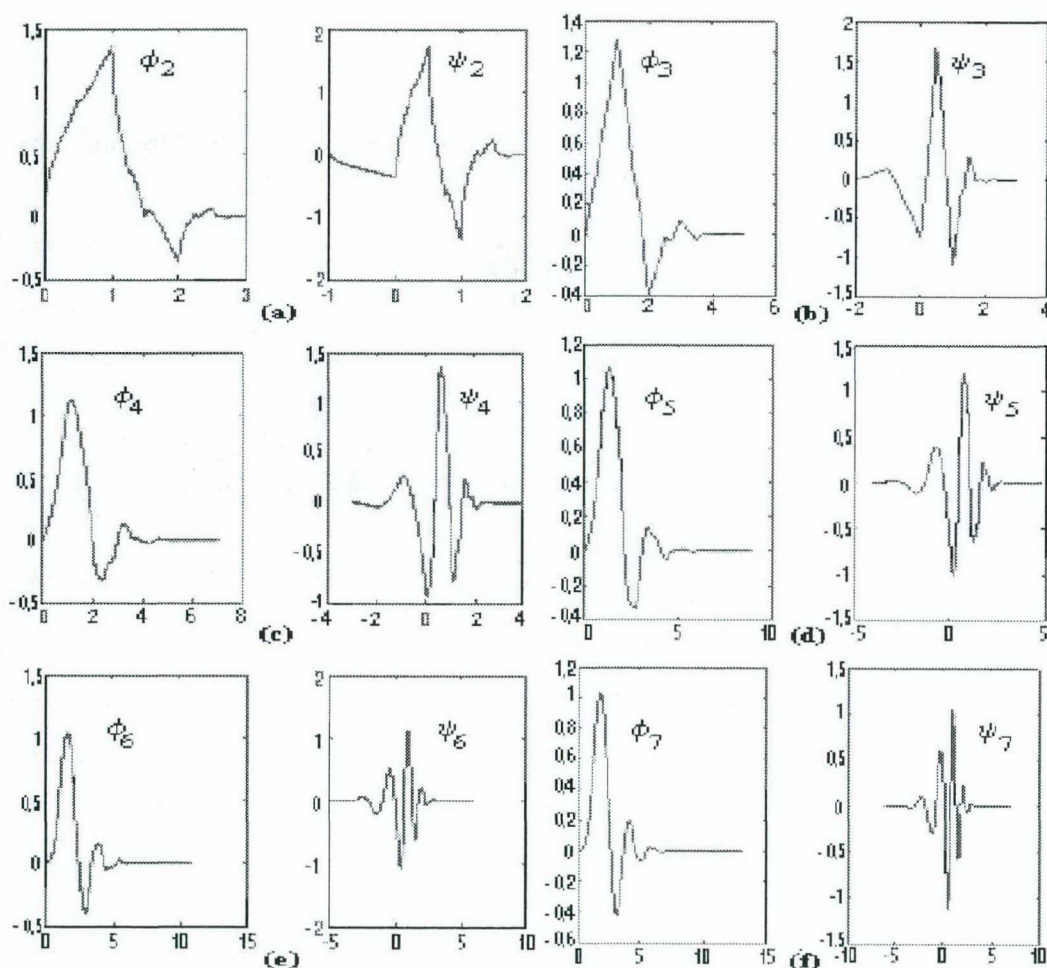


Figura 3.17: Funções de escala e *wavelets* de Daubechies. (Modificado de *Réalisation d'une bibliothèque C de fonctions ondelettes* [20]).




Figura 3.18: Exemplos de funções *wavelet* disponíveis no aplicativo Matlab 5.0<sup>®</sup>. Funções de Haar, Daubechies 2, Symlet 4, Coiflet 1, Coiflet 5 e Biortogonal 2.4 (nesta, a fração corresponde às ordens das funções de decomposição e de reconstrução).

### ***A Representação Tempo-Freqüência: Escalogramas***

A variação da escala  $a$  nas *wavelets* é inversamente proporcional à variação da freqüência. Por esta razão, o espectro de potências de componentes de uma WT não é dito como dependente da freqüência, mas sim, da escala  $a$ . E os espectrogramas da STFT são correspondentes aos *escalogramas* da WT. Notar que quando se varia a função *wavelet* segundo um valor alto de  $a$  é como se o sinal  $f(t)$  estivesse sendo passado por um filtro passa-bandas (estrito) com freqüência central baixa, já que o sinal é correlacionado com a função *wavelet*. Ao contrário, um valor baixo de  $a$  filtra o sinal em um filtro passa-bandas (largo) de freqüência central alta. Na prática, isto funciona como se estivesse ocorrendo uma decomposição de  $f(t)$  em componentes desde as mais “grosseiras” ( $a$  com valor alto e componentes de freqüência mais baixas) até as mais “finas” ( $a$  pequeno e componentes de freqüência mais altas) [20]. Esta aproximação de  $f(t)$  conhecida por *banco de filtros multiresolução* é extremamente interessante para utilização em algoritmos de reconhecimento de estruturas [20], pois permite que se rastreie as variações de amplitude, freqüência e fase de uma estrutura específica, como é o caso dos paroxismos em EEG.



O escalograma, ao invés de manter  $\Delta t$  e  $\Delta \omega$  fixos, como na STFT, mantém fixa apenas a relação de Heisenberg entre estes. A Figura 3.19 ilustra a representação gráfica da distribuição tempo-escala na WT. O eixo vertical do escalograma representa a escala  $a$  (aumentando no sentido inverso a  $\omega$ ), o eixo horizontal representa o tempo  $t$  e os valores de translação  $\tau$  aumentando com  $t$  e por fim, os valores das potências relativas de cada componente de escala, para um determinado  $\tau$ , são obtidos do quadrado do módulo da CWT, isto é:

$$\text{Potências componentes}_{a,\tau} \propto \frac{dt, da}{a^2} |\text{CWT}_{a,\tau}[f(t)]|^2 \quad (\text{Eq. 3.33})$$

Para que se possa representar as três variáveis relacionadas a CWT (a saber,  $a$ ,  $\tau$  e potência da componente) utiliza-se normalmente um gráfico 2D, onde os valores de potência são representados por cores ou níveis de cinza (Figura 3.20), ou um gráfico 3D com o eixo  $z$  associado à potência, dependente das outras duas variáveis (Figura 3.21).




Figura 3.19: Representação tempo-escala na Transformada *Wavelet* Contínua.

### 3.2.4 A Transformada *Wavelet* Discreta - DWT

A Transformada *Wavelet* Contínua mapeia um sinal unidimensional em uma representação conjunta tempo-escala, a qual é extremamente redundante [121] quando a base *wavelet* não é *ortogonal*. Em muitas aplicações, porém, o interesse maior é na *compactação de dados*, isto é, representação do sinal  $f(t)$  utilizando-se um mínimo possível de parâmetros [121]. Com o objetivo de se diminuir a redundância desenvolveu-se a Transformada *Wavelet* Discreta, na qual os valores da translação  $\tau$  e da escala  $a$  vão variar discretamente, de forma a se “forçar” a ortogonalidade das janelas de tempo atuais, em relação à largura das janelas de tempo anteriores. Se a largura das janelas  $\Delta t$  for tal que a largura atual,  $\Delta t^n$  seja sempre a metade (igual a  $1/2\Delta t^{n-1}$ ), ou o dobro (igual a  $2\Delta t^{n-1}$ ) de  $\Delta t^{n-1}$ , a ortogonalidade estará garantida na maior parte dos casos. Assim:






Figura 3.20: Transformada *Wavelet* Contínua de sinal de EEG, no alto. Notar que a presença de espículas nos intervalos  $[200, 400]$  e  $[600, 800]$  gerou valores altos (mais escuros) de potências dos coeficientes no escalograma e para valores de escala mais baixos.




Figura 3.21: Representação tempo-frequência de um sinal que consiste de três senoidais consecutivas de frequências fundamentais  $f_1, f_2, f_3$ , respectivamente e de um transiente em  $t_3$ . O sinal correspondente no domínio do tempo é mostrado no alto, e o respectivo escalograma 3D é simulado abaixo. Notar que a ocorrência do transiente no intervalo  $[t_3, t_4]$  gerou uma célula no escalograma de baixa escala e com largura de banda maior, bem localizada no tempo. Já as outras células correspondem a componentes com frequências bem definidas e portanto, estão bem localizadas em frequência.

$$\text{DWT}_{a,\tau}[f(t)] = \frac{1}{\sqrt{a_0^i}} \int_{-\infty}^{+\infty} f(t) \cdot \psi^*\left(\frac{t - k\tau_0 a_0^i}{a_0^i}\right) \cdot dt \quad , \text{com } i, k = 0, 1, 2, \dots$$

(Eq. 3.34)

onde o fator de translação  $\tau = k \cdot \tau_0 \cdot a_0^i$  depende do fator de escala  $a$ ;  $a_0 > 1$  e  $\tau_0$  são os valores iniciais de escala e translação;  $i$  e  $k$  são inteiros e o termo  $1/\sqrt{a_0^i}$  é um fator de normalização. A distinção da DWT em relação à CWT depende fortemente da escolha de  $a_0$  e  $\tau_0$ . Se  $a_0$  é próximo de 1 e  $\tau_0$  é pequeno, a DWT aproxima-se da CWT [121]. Normalmente, utiliza-se  $a_0 = 2$  que corresponde ao intervalo de amostragem de *Nyquist*, em frequência [121]. O fator de translação  $\tau_0$ , por sua vez, normalmente é escolhido como 1.

Em outras palavras, cada base determinada por cada função *wavelet*, derivada da *wavelet*-mãe via dilatações e translações discretas (e não contínuas, como ocorre na CWT), segundo um determinado  $k$  e um determinado  $i$  forma um espaço ortogonal à todas as outras funções *wavelet*, derivadas da mesma *wavelet*-mãe, mas com diferentes valores para  $i$  e  $k$ :

$$\{\psi_{i,k}(t)\}_{i,k \in \mathbb{Z}} \perp \{\psi_{j,n}(t)\}_{j,n \in \mathbb{Z}} \text{ para } \forall j \neq i, n \neq k \quad (\text{Eq. 3.35})$$

Tudo isto para evitar-se a redundância da CWT. E a soma de todos estes subespaços ortogonais forma um espaço ortonormal esparso, capaz de decompor ortogonalmente qualquer função em  $L^2(\mathfrak{R})$ <sup>11</sup>.

O escalograma também deixa de ser contínuo e as componentes de frequência da Transformada *Wavelet* da função contínua  $f(t)$  serão representadas em 2D por pontos espaçados coloridos (ou em níveis de cinza), ou por retângulos nas posições  $[\tau, a]$  do escalograma (Figura 3.22).

O eixo da escala  $a$  pode ser substituído por  $\log a$  para que os pontos fiquem igualmente espaçados neste sentido e para facilitar a visualização. Neste caso, freqüentemente os intervalos passam a ser denominados de *níveis* de decomposição, ao invés de valores de *escala* (Figura 3.23).

<sup>11</sup> Uma função  $f$  está em  $L^2(\mathfrak{R})$ , o espaço das funções quadrático-integráveis, se:  $\int_{\mathfrak{R}} f^2 < \infty$






Figura 3.22: Representação tempo-escala na Transformada *Wavelet* Discreta




Figura 3.23: Ilustração comparativa entre escalogramas referentes à DWT e à CWT de um mesmo sinal, representado no alto (Tutorial do Matlab 5.0®)

### A Função Escala

Como foi citado anteriormente, cada função *wavelet* filtra o sinal  $f(t)$  em uma determinada banda, de largura dependente da frequência central. Falta um detalhe, porém, para que o raciocínio possa ser concluído: como analisar a componente DC, ou valor médio, de um sinal se apenas dispuser-se de filtros passa-banda, centralizados a partir de uma frequência inicial inversamente proporcional a  $a_0$ ? Para solucionar esta questão, ou seja, para que se possa extrair o comportamento mais “lento” de um sinal são utilizadas, então, as *Funções de Escala*  $\phi(t)$ .

As funções de escala ou funções *wavelet-pai*, como também são conhecidas, são também derivadas da mesma função *wavelet-mãe* que gera as funções *Wavelet* “filhas” e são ortogonais em relação às mesmas. Além disto, e sobretudo, as funções de escala possuem, em frequência, a característica de filtros passa-baixas, como ilustra a Figura 3.24.

O somatório dos conjuntos de funções *Wavelet* e funções de escala a partir de uma única *wavelet-mãe* vai gerar um espaço ortonormal, capaz de decompor ortogonalmente qualquer função em  $L^2(\mathbb{R})$ . As funções de escala foram aproveitadas, principalmente, no desenvolvimento de algoritmos de implementação computacional da DWT, tal como será visto na seção seguinte.




Figura 3.24: À esquerda – (a) Funções de escala  $\phi(t)$  em níveis decrescentes de resolução ( $j = 0, -1, -2, \dots, -6$ ). (b) Transformadas de Fourier correspondentes às funções de escala. À direita: Funções *wavelet*  $\psi(t)$  em níveis decrescentes de resolução ( $j = 0, -1, -2, \dots, -6$ ). (b) Transformadas de Fourier correspondentes às funções *wavelet*.



### 3.2.5 A Transformada Wavelet Rápida - FWT

Uma das características mais interessantes da Transformada *Wavelet* é que esta, assim como a Transformada de Fourier, também admite uma implementação “rápida”, a FWT (“*Fast Wavelet Transform*”, em inglês). A origem deste algoritmo remete aos estudos de Stephane Mallat e Yves Meyer [94], em 1993, que adaptaram um algoritmo de processamento de imagens, chamado de *algoritmo da pirâmide*, para a análise *Wavelet* multiresolução.

O algoritmo da FWT utilizado neste trabalho é baseado no “Esquema de *Lifting*” [132][133], desenvolvido por Sweldens em 1994, por sua vez inspirado nos trabalhos de Lounsbery *et al.* [90] e Donoho [40].

O custo computacional do algoritmo FWT é um dos mais baixos para Transformações, senão o mais baixo. Se  $O$  é uma constante (geralmente de valor 2) e  $N$  é a dimensão do vetor, em amostras, a ser analisado, pode-se afirmar que o algoritmo FWT exige apenas  $ON$  operações (nem sempre complexas), enquanto o algoritmo da Transformada Rápida de Fourier - FFT, por exemplo, utiliza  $ON \log N$  operações complexas. Além disto, algumas operações próprias do FWT tornam sua utilização ainda mais veloz, como é o caso dos passos de *subamostragem*, que reduzem geometricamente a dimensão dos vetores dos sinais sendo analisados, a cada nível de decomposição.

Em linhas gerais, o algoritmo FWT implementa a decomposição do sinal discreto  $f(n)$  utilizando *Bancos de Filtros Espelho Multiresolução* (também chamados de *Multiescala*) em *Quadratura*, ou seja, um conjunto de filtros  $H(n)$  derivados das funções de escala, que vão extrair as características médias (ou “*Aproximações*”, ou ainda “*características grosseiras*”) do sinal somado a um conjunto de filtros  $G(n)$  derivados das funções *wavelet*, os quais por sua vez extrairão as características de alta frequência (ou “*Detalhes*”, ou ainda “*características finas*”) do sinal. Além disto, a cada nível de decomposição, o sinal é *subamostrado* ou *decimado*, normalmente por um fator 2, de forma que se garanta a ortogonalidade das componentes resultantes<sup>12</sup>, como mostra a Figura 3.25. Já a Figura 3.26 ilustra a aplicação de decomposição de um sinal por FWT, as componentes de detalhe e de aproximação geradas e os sinais reconstruídos a partir de cada uma das componentes.

Uma descrição mais detalhada do algoritmo FWT pode ser encontrada no ANEXO A. Maiores referências sobre algoritmos FWT poderão também ser encontradas nos trabalhos [134][121][20][135].

<sup>12</sup> É fácil verificar que toda função  $f(t)$  par, de média zero e período  $T$  é sempre ortogonal à função cujo suporte tem o dobro da sua dimensão (período igual a  $2T$ ):  $f(t) \perp f(t/2) \perp f(2t) \dots$

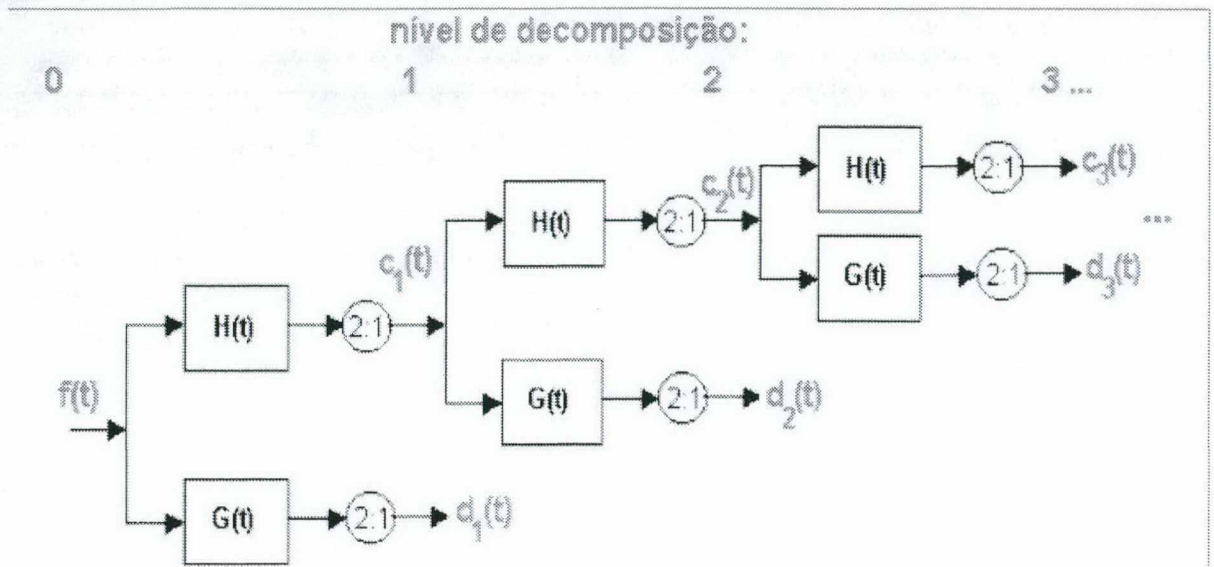


Figura 3.25: Aplicação de Filtros Multiresolução em Quadratura a um sinal  $f(t)$  (também chamado de  $c_0(t)$ ). Os filtros  $G(t)$  extraem os detalhes  $d_i(t)$ , ou  $cd_i$ , do sinal. Os filtros  $H(t)$  extraem as aproximações do sinal (características "coarser")  $c_i(t)$ , ou  $ca_i$ , em níveis  $i$  cada vez menores de refinamento, com aumento da escala.




Figura 3.26: Acima e à esquerda – sinal original, posteriormente decomposto em 3 níveis através de FWT no MATLAB®. À esquerda e de baixo para cima – componente de detalhe 1 ( $cd1$ ), componente de detalhe 2 ( $cd2$ ), componente de detalhe 3 ( $cd3$ ) e aproximação 3 ( $ca3$ ). À direita e de baixo para cima: sinal reconstruído a partir de  $cd1$ , sinal reconstruído a partir de  $cd2$ , sinal reconstruído a partir de  $cd3$  e sinal reconstruído a partir da  $ca3$ . Notar que, à medida que aumenta o valor da escala diminuem os valores das frequências envolvidas nas componentes.



## 4. SISTEMAS EXISTENTES

O presente capítulo visa discorrer sobre alguns dos sistemas computadorizados desenvolvidos para se realizar detecção de descargas epileptiformes (DEs) e/ou classificação destes eventos paroxísticos no EEG e também vem a ilustrar o emprego das ferramentas de análise referidas nos capítulos anteriores e discutir eventualmente seus desempenhos. Cada uma das seções do capítulo refere-se a um tipo de abordagem de processamento do sinal de EEG, o qual será ilustrado por meio da descrição de sistemas organizados em ordem cronológica crescente.

### 4.1 Análise Convencional

#### 4.1.1 Reconhecimento por regras de decisão e modelagem de Espículas

Um dos primeiros sistemas de detecção automática de espículas em EEG foi desenvolvido pelos Dr. Gotman e Dr. Gloor, do Montreal Neurological Institute, Canadá, em 1976 [54] e seus estudos tornaram-se referência para uma série de outros que o seguiram.

O princípio de detecção é o estabelecimento de regras de decisão baseadas em características físicas dos sinais a serem analisados. No primeiro estágio do algoritmo, a amplitude atual (época) do sinal de EEG é comparada com o valor da amplitude média, calculada a partir de épocas passadas do EEG. É ajustado também um valor de *threshold* que fará o disparo dos próximos estágios do algoritmo, quando superado pela comparação no primeiro estágio. Se não houver um pico de amplitude, na época atual, que ultrapasse o *threshold*, o sistema simplesmente passa à análise da próxima época.

Os próximos estágios do algoritmo consistem exatamente nas regras de decisão, que por sua vez utilizam regras de descrição parametrizada de espículas, em sinais de EEG, para decidir se durante a época atual houve ou não a presença de uma espícula. Os valores assumidos para os parâmetros foram obtidos empiricamente.

As regras de descrição, ou *Modelos de Gotman*, quantificam, por exemplo, o que se chamou de “agudeza” do evento espicular e que causou a superação do *threshold*, tempo de subida deste evento candidato a *spike*, tempo de descida, amplitude absoluta, amplitude pico-a-pico, amplitude diferencial entre o ponto máximo do evento candidato e o ponto mínimo que o precede, derivadas no ponto, etc. Também há uma comparação entre ocorrências em canais vizinhos, para

se detectar *reversão de fase*, o que aumentaria a indicação de foco epiléptico. Enfim, todos estes valores são quantificados e preenchem a tabela de parâmetros, a qual é submetida às regras de decisão e os resultados provenientes destas são armazenados juntamente com outros detalhes sobre os canais, hora da aquisição, instante de ocorrência do possível *spike*, etc. As épocas e parâmetros referentes à possível ocorrência de *spikes* são, então, armazenados em separado, para posterior apresentação ao revisor de EEGs.

Detalhes acerca dos Modelos de Gotman e dos algoritmos podem ser obtidos em inúmeras referências da área, tais como [54][55][56][57][58][59].

#### **4.1.2 Sistema de Monitoração remoto com reconhecimento por Modelos de Gotman**

Em 1992, Ives, Mainwaring e Schomer [72] desenvolveram um sistema formado por um equipamento para registro e monitoração portátil (para ser utilizado no domicílio do paciente) de eventos epileptiformes no EEG, associado a rotinas de análise computacional *on-line*, via Modelos de Gotman.

O objetivo deste trabalho era diminuir o número de internações de pacientes suspeitos de epilepsia, para a realização de exames de eletroencefalograma em hospital. Isto porque, segundo o artigo [72], está provado que a internação de um paciente dobra o custo de tratamento deste e que o número de crises em um paciente epiléptico reduz-se sensivelmente quando este é internado. Ou seja, a melhor opção seria fazer-se o acompanhamento de longo termo do paciente no ambiente mais econômico e mais propício à ocorrência das crises: seu próprio domicílio. Para tanto, seria necessário desenvolver-se um equipamento prático, econômico, de dimensões e de peso reduzidos, que pudesse ser “instalado” facilmente no paciente, que tivesse capacidade para armazenar o máximo possível de informações acerca das crises eletroencefalográficas e que pudesse ser facilmente interpretado posteriormente pelo eletroencefalografista responsável.

Os autores escolheram utilizar eletrodos de ouro e prata, com 16 canais em 125 montagens bipolares, de volume e peso mínimos. Todo este conjunto de eletrodos e um pré-amplificador de 0,5 a 70 Hz foram afixados à cabeça do paciente. A saída do pré-amplificador foi interligada a um “registrador de cintura”, uma memória por fita cassete, com capacidade para armazenar até 5 eventos, de 4 minutos cada, no EEG de 16 canais. Esta memória estava conectada a um computador domiciliar portátil, através de um cabo de 6 metros, o qual monitora e capta os eventos eletroencefalográficos que se adequem aos Modelos de Gotman [55][58], arquivando-os para posterior análise no computador central, no hospital. O arquivamento de dados de EEG ocorria, por exemplo, quando determinadas restrições dos modelos fossem satisfeitas, tais como detecção de espículas, ondas agudas ou crises epiléticas eletroencefalográficas rítmicas.



### 4.1.3 Reconhecimento por Correlação com Função Impulso

Outro sistema analisador portátil, para monitoração de longo termo de sinais de EEG, foi desenvolvido por Stelle e Comley [130], em 1989. O analisador foi programado para detectar automaticamente e em tempo real, pré-cursos epilépticos (CEOs de 3 Hz) especificamente relacionados ao início de crises de Ausência Generalizada.

O processo de detecção das espículas desenvolvido é representado pela função de transferência ímpar  $H_d(f)$ , da Figura 4.1a, que produz uma saída bipolar (Figura 4.2b). Isto é, o algoritmo de detecção em si consiste da convolução do sinal de EEG candidato com a resposta ao impulso  $h(n)$  discreta.




Figura 4.1: Características de frequência e fase do sistema de detecção de espículas. (a) Diferenciador. (b) Diferenciador + TH. (Modificado de *Portable Analyser for Real-Time Detection of the Epileptic PreCursor* [130])




Figura 4.2: Estágios do algoritmo de detecção de espículas. (a) Padrão Complexo Espícula-Onda, CEO, apresentado à entrada. (b) Saída após Operador Diferencial. (c) Saída após Operadores Diferencial + TH. (Modificado de *Portable Analyser for Real-Time Detection of the Epileptic Pre-Cursor* [130])

O problema é que esta função de transferência, por ser de resposta bipolar, exige a utilização de dois *thresholds*, na determinação por checagem de nível para a ocorrência ou não da espícula, pertencente ao possível CEO. Como a saída do diferenciador não será simétrica, na maioria dos casos, a confiabilidade do detector pode ser comprometida.

Uma solução encontrada pelos pesquisadores foi acrescentar um estágio de processamento à saída do diferenciador: um Operador de Mudança de Quadratura de Fase, implementado através de Transformada de Hilbert. Este artifício fez com que a saída passasse a ser uma função unipolar (toda a informação relacionada ao CEO está contida em um único pulso positivo - Figura 4.2c) e assim, todas as componentes de alta frequência continuaram sendo amplificadas, mas as componentes de fase passaram a ser nulas para todos os valores de frequência, como mostrado na Figura 4.1b. Ainda é necessário um valor de *threshold* para comparação, mas este é imune a problemas de assimetria para o diferenciador simples. O custo computacional sofreu um aumento, mas que é compensado pela maior eficiência do algoritmo.

Também foi utilizado um “filtro cúbico” para amplificar os eventos de interesse na saída do diferenciador e reduzir o ruído de fundo. Desta forma, a saída do diferenciador com Transformada de Hilbert foi elevada à potência de três e escalonada, antes do estágio de comparação com o *threshold*, para facilitar a identificação dos CEOs (Figura 4.3).




Figura 4.3: Operação do detector de espículas completo. (a) CEO apresentado à entrada. (b) Saída do detector de Espículas. (c) Saída do filtro cúbico. (Modificado de *Portable Analyser for Real-Time Detection of the Epileptic Pre-Cursor* [130])

Finalmente, foi necessário também que se implementasse um dispositivo para detectar as ondas lentas do CEO e para filtrar os artefatos musculares, críticos em um sistema portátil, como é o caso deste trabalho. Esta implementação foi feita na forma de um filtro passa-baixas Butterworth de quarta ordem, com uma frequência de corte de 7 Hz, seguido por um discriminador de nível.

O algoritmo completo de detecção foi testado em um computador Motorola SYS133, com dados pré-registrados de EEG, amostrados a 600 Hz e limitados a uma banda de 70 Hz. Os resultados foram considerados animadores pelos autores do artigo [130], mas os problemas com o ruído muscular persistiram.

Esta susceptibilidade à influência dos artefatos musculares é, na verdade, o grande obstáculo a ser superado pelos sistemas de detecção automáticos: pois, se estes diminuem a sensibilidade aos ruídos, também perdem sensibilidade aos paroxismos, gerando muitas detecções falsas-negativas e se aumentam a sensibilidade aos paroxismos, também é aumentada a sensibilidade aos ruídos, gerando-se os falsos-positivos.

## 4.2 Análise através de RNAs

Apesar das vantagens oferecidas pelas RNAs como ferramentas de detecção e análise de eventos em EEGs, durante muito tempo apenas a Abordagem Simbólica (mais especificamente, aqueles sistemas que utilizavam o *Raciocínio Baseado em Regras* - RBR) era aplicada a sistemas de reconhecimento automático de paroxismos no EEG (como feito nos sistemas de Pradhan *et. al.* [106] e Webber *et. al.* [139]). Alguns sistemas obtiveram considerável êxito nesta tarefa, tais como os de Gotman em 1985 [56], Frost em 1985 [47], Gotman em 1982 [55], Gotman em 1979 [58] e Webber em 1993 [138]. O problema é que por mais que houvesse a preocupação em se estabelecer o conjunto ótimo de regras, ainda assim o número de falsos positivos era muito grande. Era comum o sistema RBR confundir paroxismos normais (tais como os relacionados ao sono, p. e.) com paroxismos epileptogênicos. Além disto, o desenvolvimento de tais sistemas especialistas é difícil por envolver extração e modelagem de conhecimento e suas execuções demandam um considerável custo computacional [106].

As RNAs representam uma alternativa para se fazer este reconhecimento de padrões epileptiformes em EEG, para situações reais e envolvendo grande volume de dados [106][139], pois o custo computacional de processamento de um sinal de EEG em uma RNA já treinada é mínimo. Além disto a RNA pode ser devidamente treinada para diminuir o risco de falsos positivos e falsos negativos na detecção e, a partir disto, tem a capacidade também de *generalizar* sobre aqueles casos que lhe foram apresentados, dependendo do conjunto de treinamento utilizado.

O problema principal na utilização das RNAs para este fim específico é a definição sobre a topologia de rede, o algoritmo de treinamento e a forma de apresentação dos dados à rede, a serem



empregados. Outras questões secundárias referem-se ao tratamento que será dado aos aspectos clínicos que individualizam os paroxismos, aos tratamento dos dados de EEG (a fonte do banco de registros de EEG, forma de aquisição, pré-processamento, número de canais de entrada, etc) e ao desempenho de cada rede em tempo-real ou não [106]. Particularmente a questão do pré-processamento do sinal é polêmica, já que alguns autores aconselham-no [139][77], ao passo que outros, não [106].

A grande maioria dos sistemas desenvolvidos até o presente momento utilizam a rede *feedforward* com treinamento *backpropagation* [5][50][139] para análise de EEGs e/ou detecção de DEs, principalmente por ser a rede neural mais conhecida, explorada e disponível na bibliografia. E o primeiro sistema descrito utiliza esta topologia, como segue.

#### **4.2.1 Rede Feedforward para reconhecimento de Espículas e Ondas Agudas (SSWs) com entrada paramétrica**

Um dos primeiros sistemas de reconhecimento automático de paroxismos (espículas e ondas rápidas) epileptiformes em EEG e utilizando redes neurais artificiais foi desenvolvido por Gabor e Seyal [50], em 1992. Os pesquisadores desejavam um sistema neural de reconhecimento que também levasse em conta os aspectos espaciais da análise do EEG, isto é, pudesse discriminar qual(is) eletrodo(s), localizado(s) em determinada(s) região(ões) do escalpo, apresentava(m) os paroxismos.

Também tinham por objetivo utilizar uma ferramenta neural que apresentasse níveis de *Seletividade*<sup>13</sup> e *Sensibilidade*<sup>14</sup> compatíveis com a análise manual convencional. A velocidade (relação entre o tempo de duração da análise de grupo de dados por parte da rede e o tempo de duração total de aquisição do mesmo) e a aplicabilidade clínica prática (relacionada à capacidade da rede em generalizar resultados de paciente para paciente, à facilidade de obtenção do conjunto de treinamento, ao tamanho do conjunto de treinamento e à simplicidade e baixo custo do *hardware* requerido para implementação da rede) foram fatores também decisivos para a escolha da forma de implementação da rede neural de reconhecimentos de DEs em EEG, por Gabor e Seyal.

<sup>13</sup> A medida de *Especificidade* ou *Seletividade* de um processo de detecção de padrões refere-se à habilidade da ferramenta em discriminar entre padrões relevantes e irrelevantes, isto é, é inversamente proporcional à frequência de detecções falsamente-positivas apresentada pela ferramenta [50]. Pode ser calculada por:  $(100 \times DC)/D$ , onde  $DC$  é o número de detecções corretas obtidas e  $D$ , o número total de detecções obtidas (corretas + falsos-positivos).

<sup>14</sup> O parâmetro *Sensibilidade* é a medida da habilidade da ferramenta computacional de reconhecimento de padrões em identificar padrões relevantes, ou seja, está inversamente relacionada à frequência de detecções falsamente-negativas [50]. Pode ser calculado por:  $(100 \times DC)/DE$ , onde  $DC$  é o número de detecções corretas obtidas e  $DE$ , o número de detecções que deveriam ter sido obtidas (corretas + falsos-negativos).



A topologia da rede escolhida foi a *feedforward*, 3 camadas (camadas de entrada, *hidden* e de saída), com algoritmo de treinamento *back-propagation*, sem conexões de realimentação e entre neurônios de uma mesma camada. A rede possuía 8 neurônios de entrada, um para cada canal de EEG, para permitir a discriminação espacial de paroxismos focais, por exemplo. Também foram utilizados 8 neurônios para a camada *hidden* e apenas 1 neurônio para a saída [50].

As particularidades desta rede começam na forma de apresentação dos dados à rede. Ao invés dos dados crus, apresentados serialmente, os pesquisadores utilizaram um parâmetro que chamaram de “taxa de inclinação média da tensão”,  $d\bar{V}/dt$ , o qual é calculado para uma determinada época do sinal através da média entre as variações de amplitude do sinal digitalizado de EEG, neste intervalo.

Assim, para a obtenção do conjunto de treinamento, um especialista em eletroencefalografia é encarregado de selecionar espículas ou ondas rápidas nos canais de EEG, que considera como epileptogênicos (a sigla SSW foi utilizada para os mesmos) e uma vez escolhido um SSW, dois outros parâmetros, taxa de inclinação *pré-pico* e taxa de inclinação *pós-pico* são calculados. A taxa de inclinação *pré-pico* consiste na variação da amplitude do sinal antes do pico máximo de amplitude do paroxismo SSW. Analogamente, a taxa de inclinação *pós-pico* refere-se à variação da amplitude após o pico máximo do SSW.

Duas redes são utilizadas para cada canal: a rede 1 recebe os valores de inclinação *pré-pico* daquele canal e a rede 2, os parâmetros de inclinação *pós-pico* do mesmo canal.

Durante o treinamento, a atualização dos pesos é feita segundo o erro da rede em classificar os padrões de treinamento, definidos pelos especialistas como “padrões corretos”, isto é, com valores de ativação de saída iguais a 1. Porém, a rede receberá também como padrões de treinamento, vetores “incorretos”, isto é, não referentes a paroxismos epileptogênicos. Ao invés de tomar aleatoriamente estes padrões de treinamento incorretos, de uma determinada população, Gabor e Seyal escolheram “fabricar” estes padrões incorretos, derivando-os estatisticamente dos valores de média e desvio-padrão do conjunto de padrões corretos de treinamento, para cada canal [50]. Foram utilizados apenas de 4 a 6 padrões de treinamento para cada rede, obtidos de 5 pacientes comprovadamente epiléticos através de registro bipolar, sistema 10-20, em fita magnética, posteriormente digitalizado em 8 bits a uma taxa de 128 Hz de amostragem. Os sinais digitais foram enviados a um microcomputador IBM-PC 33 MHz, processador Intel 486. Foi feita uma filtragem de baixas frequências, menores que 2 Hz e uma filtragem digital de médias para reduzir artefatos musculares nos sinais.

A inicialização dos pesos foi feita de forma randômica e o erro RMS máximo permitido na saída da rede ficou entre 0,01 e 0,003. O valor final de “certeza” da detecção de um SSW foi arbitrado como sendo uma combinação das ativações de saída com um certo peso ponderado para cada rede. Este peso pode ser selecionado pelo usuário, mas os pesquisadores desenvolveram toda uma avaliação da sensibilidade de cada uma das redes, 1 e 2, em função das suas maior ou menor capacidade de fazer a detecção correta [50]. Desta forma, se uma rede tivesse maior sensibilidade que a outra, teria o valor de peso também maior. Por exemplo, digamos que tenha-se descoberto que a rede 1, para um determinado conjunto de treinamento, tenha apresentado sensibilidade 2 vezes maior que a rede 2. Isto significa que o peso da rede 1 no cálculo da “certeza” da detecção deve ser de 0,66 e o da rede 2 deve ser 0,33. Assim, se o valor de ativação da saída da rede 1 foi de 0,92 para um determinado SSW e para a rede 2 foi de 0,89, o valor da certeza final na detecção correta deste SSW será igual a:  $0,92 \times 0,66 + 0,89 \times 0,33 = 0,90$ .

Finalmente, quanto aos resultados do sistema, a sensibilidade das redes, segundo os autores, chegou a atingir 94,2% de detecções corretas. A seletividade das redes 1 e 2 foi dependente dos valores de *threshold* utilizados nas saída das mesmas. Se fosse arbitrado que um sinal seria considerado SSW apenas se a saída ultrapassasse o valor de 0,9 de ativação, então o número de falsos-positivos era baixo (3,7%), porém aumentava o número de falsos-negativos nas detecções. Já para o valor de *threshold* igual a 0,825 o número de falsos-positivos aumentou para 20,9%.

#### **4.2.2 Rede Feedforward para reconhecimento de DEs, com comparação entre entradas cruas e paramétricas**

Um estudo muito interessante foi realizado por Webber *et al.* [139], em 1994, que implementaram uma RNA para detecção de DEs e ainda fizeram uma comparação do desempenho desta rede, quando alimentada com dados “cruas” e com dados parametrizados de EEG.

Foram tomados aleatoriamente 10 sinais de EEG completos (4 canais), com durações variando entre 3 a 5 min, adquiridos durante estados de sono e de vigília através de montagem bipolar longitudinal, com eletrodos dispostos através do sistema 10-20. O equipamento utilizado na aquisição foi um amplificador GRASS EEG, modelo 12A5, a uma taxa de 200 Hz/canal, com posterior filtragem dos sinais na banda de frequência 0,3-70 Hz.

Metade destes sinais foi utilizada para treinamento da rede e metade, para teste da rede neural. Além disto, foi acrescentado ao conjunto de treinamento um sinal de EEG constituído também por vários artefatos oriundos de movimentos das pálpebras dos olhos, para treinar a rede a reconhecer este tipo de ruído. Todos os sinais foram analisados por um especialista em



eletroencefalografia, que classificou os eventos encontrados em “definitivamente epileptiformes”, “possivelmente epileptiformes” e “não-epileptiformes”.

Os sinais de EEG também passaram por uma etapa de processamento, antes de serem utilizados como entradas da RNA. Esta parametrização consistiu de uma “pré-deteção” de sinais candidatos a DEs (CDEs), por assim dizer, e foi dividida em duas fases: na primeira fase apenas um dos canais era investigado. Este canal era filtrado em um passa-baixas de 27 Hz, para se evitar paroxismos de altas frequências (não-relacionados à epilepsia, mas sim a artefatos musculares, p.e.) e dividido em épocas de 2 s de duração. Para cada época foi computada toda uma estatística, baseada em 15 parâmetros de amplitude, largura e inclinação (“agudeza” -  $d^2x/dr^2$ ) das formas de onda presentes na época. Caso alguma das formas de onda superasse *thresholds* destes parâmetros, esta seria marcada como elemento de descarga epileptiforme (EDE) e passaria à fase seguinte. Na segunda fase, os segmentos dos demais canais, referentes ao segmento do primeiro canal que contivesse um EDE, seriam analisados. Se fosse encontrado um segundo EDE, em pelo menos um canal do mesmo laço bipolar que o primeiro canal já analisado na primeira etapa e na mesma janela de tempo de 30 ms após o EDE do primeiro canal, a forma de onda seria marcada como candidata a DE (CDE). Todos os parâmetros estatísticos seriam, então, recalculados para os outros 3 canais e o CDE seria apresentado como entrada à ANN. A parametrização diminuiu sensivelmente o esforço computacional do sistema, na medida em que desprezou grandes quantidades de artefatos e segmentos de EEG “pobres em DEs” [139]. Obviamente o maior risco deste procedimento é o de perda de paroxismos focais na análise, mas com o registro bipolar este risco é mínimo e a redução de custo computacional compensaria o mesmo.

A rede neural utilizada foi a elementar *feedforward* de três camadas, treinada com algoritmo *backpropagation*. A topologia da primeira camada variou para a análise com dados crus e parametrizados. No primeiro caso apresentou-se diretamente épocas do sinal de EEG à rede e portanto foram utilizados 40 neurônios de entrada (épocas de 400 ms, amostradas a 100 Hz). No segundo caso, porém, os parâmetros de cada época é que foram apresentados à entrada da rede, que ficou com 60 neurônios (4 canais  $\times$  15 parâmetros estatísticos). Todas as formas de entrada foram, antes, normalizadas entre 0 e 1. A camada *hidden*, de 12 neurônios, e a camada de saída composta por apenas 1 neurônio, utilizaram funções de ativação sigmoidais.

Os pesquisadores escolheram balancear os dados, descartando aleatoriamente muitos segmentos não-epileptiformes, que apareciam em muito maior quantidade que os epileptiformes, de forma a utilizar praticamente uma quantidade igual de segmentos epileptiformes e não-epileptiformes no treinamento.



A rede foi treinada em 1000 ciclos, com coeficiente de aprendizado inicial igual a 0,02 e momentum inicial igual a 0,9. Estes valores, relativamente altos segundo os autores [139], foram utilizados para se garantir uma convergência rápida da rede, ainda que assim se corra o risco de a mesma convergir para um mínimo local mais facilmente.

Após o primeiro treinamento e os testes, foi realizada uma revisão dos dados dos conjuntos de treinamento e teste, segundo as discrepâncias entre a detecção realizada pelo especialista e pela rede. Os eventos marcados pela rede e não pelo especialista e vice-versa, os marcados pelo especialista e não pela rede, foram revistos. Alguns foram eliminados e outros acrescentados de forma a tornar-se os conjuntos de dados mais consistentes e eliminar ao máximo os falsos positivos e os falsos negativos da detecção.

A performance da rede para os novos conjuntos de treinamento e de teste foi claramente favorável à análise com os dados parametrizados, no entanto, os pesquisadores ressaltam que, ao que parece, a rede necessita de mais dados crus que dados parametrizados para a mesma performance, o que não elimina a possibilidade de se utilizar um conjunto de treinamento de dados crus muito maior e se superar a performance da rede com dados parametrizados.

A Tabela 4.1 ilustra a sensibilidade e a seletividade na detecção de DEs por parte da rede, como funções do *threshold* definido na saída da rede, que limita as classes possíveis para a saída (classe “definitivamente DE”/“possivelmente DE” e classe “não-DE”). O ponto de cruzamento entre as curvas de sensibilidade e seletividade (*crossover*) é tomado como valor ótimo de performance da rede, para um dado valor de *threshold* de saída da rede.

Tabela 4.1: Comparação entre RNAs que utilizam dados crus e parametrizados como entrada. As classes “definitivamente epileptiforme” e “possivelmente epileptiforme” estão agrupadas em uma só classe. Medidas percentuais.

TIPO DE ENTRADAS	PARÂMETROS	<i>threshold</i> baixo ( $< 0,15$ )	<i>threshold</i> alto ( $> 0,90$ )	<i>threshold</i> no ponto de <i>crossover</i> ( <i>co</i> )
PARAMÉTRICAS	Sensibilidade	78,4	38,4	73,6 ( <i>co</i> = 0,3)
	Seletividade/ Especificidade	64,8	90,9	73,6 ( <i>co</i> = 0,3)
CRUAS	Sensibilidade	83,1	23,9	45,7 ( <i>co</i> = 0,3)
	Seletividade/ Especificidade	26,9	61,4	45,7 ( <i>co</i> = 0,3)

### 4.2.3 Rede LVQ para reconhecimento de DEs

Pradhan *et al.* [106], em 1996, aplicaram uma rede Vetor de Quantização Linear - LVQ [81][78] a registros de EEG obtidos a partir de 5 pacientes, comprovadamente epiléticos, com idades entre 15 e 25 anos. O sinal foi adquirido em 8 canais (Fp1, Fp2, F7, F8, T3, T4, O1, O2) a 256 amostras/(s.canal) em um equipamento Nihon Kohden [106]. Os dados foram filtrados (Butterworth de 4ª. ordem, passa-faixas de 0,05 - 32 Hz) para eliminar o nível DC e os ruídos de 60 Hz e de artefatos musculares e as saídas foram amplificadas de 1,2 a 6,2 V. Os sinais de EEG amostrados foram digitalizados a 12 bits e enviados a um microcomputador PC - AT, WorkStation HP-9000.

Por fim, os dados foram separados em épocas e cada uma destas foi analisada por 2 *experts*, que classificaram as mesmas em 3 grupos: “definitivamente epileptiforme”, “provavelmente epileptiforme” ou em “atividade normal”. Houve uma taxa de consenso superior a 95% entre os *experts* na classificação das épocas. Quanto à topologia da rede LVQ, o número de neurônios da camada de entrada era igual ao número de amostras na época (3072 amostras/época), o número de neurônios na camada competitiva era  $S_1$  e os neurônios da camada de saída linear eram  $S_2 = 3$ , referentes a cada uma das classes de padrões.

Dos 5 indivíduos, apenas os dados provenientes de 1 deles (24 épocas) foram utilizados como conjunto de treinamento para a rede LVQ. Para os testes foram utilizadas 528 épocas e os pesquisadores obtiveram índices de sensibilidade para a detecção da ordem de 91% a 97,65% e índice de especificidade de 74,8%.

O número de neurônios  $S_1$  foi variado para se investigar o desempenho da rede com esta variação e comprovou-se que, para  $S_1$ s menores ou iguais ao número de neurônios de entrada a performance da rede de fato melhorou. O problema é que, com o aumento de  $S_1$  aumentou consideravelmente também o custo computacional, em tempo e em memória. A vantagem é que a rede já treinada poderia ser aplicada quase de forma *on-line*.

Os autores fizeram também comparações desta implementação com implementações anteriores, com outras topologias de redes e outras formas de treinamento e chegaram à conclusão que os resultados que obtiveram foram satisfatórios, que o pré-processamento no sinal faz diferença nos resultados finais e que o tamanho do conjunto de treinamento está diretamente relacionado à performance da rede, porém um conjunto muito grande diminui a capacidade de generalização da rede. Os falsos positivos apontados pela LVQ foram poucos e atribuídos a artefatos e discordâncias entre os *experts*.



#### **4.2.4 Redes Neurais para auxílio ao diagnóstico de patologias neurológicas**

Também tem-se notícia de um grande sistema atualmente sendo desenvolvido no OEFAI - Austrian Research Institute for Artificial Intelligence - o ANNDEE [147]. Este sistema tem por objetivo facilitar e/ou melhorar o diagnóstico de doenças ou distúrbios neurológicos e psiquiátricos baseados no sinal de EEG, através da utilização de Redes Neurais Artificiais para realizar classificação e interpretação dos dados eletroencefalográficos [147].

O projeto ANNDEE também utiliza ferramentas tais como valores e mapas de coerência e análise estatística. Especificamente no que concerne à detecção de paroxismos epileptogênicos, o projeto ANNDEE prevê o desenvolvimento de uma rede exclusivamente para este fim.

Também várias outras instituições européias estão envolvidas no projeto, seja como provedoras de dados seja como provedores de tecnologia. Maiores informações sobre o projeto ANNDEE podem ser encontradas no site: <http://www.ai.univie.ac.at/oefai/nn/anndee/sub2.3.html>

Vários outros trabalhos foram desenvolvidos nos últimos anos, em termos de detecção de DEs utilizando-se RNAs [5][10][101][149][74][149], com algumas pequenas variações de um sistema para outro. Por esta razão os mesmos não serão aqui detalhados, sob pena de estender demasiado o capítulo.

### **4.3 Análise através de Transformadas**

Como já foi visto nas seções anteriores, o sinal de EEG, devido às suas características particulares (sinal de baixas amplitudes, não-estacionário para períodos longos de observação, sujeito a artefatos e a uma grande variabilidade, etc), representa um caso crítico em processamento de sinais. Para o especialista humano este processamento é relativamente mais simples e seu método utiliza intuitivamente um tipo de interpretação baseada em análise simultânea de tempo e frequência. Tentando simular esta capacidade humana, os cientistas passaram a aplicar ferramentas como a Transformada de Fourier de Curto Tempo (STFT) e a Transformada *Wavelet* (WT) que utilizam os dois domínios para fazer a análise do sinal, como será visto na sequência.



#### 4.3.1 Detecção de Paroxismos através da Distribuição de Wigner

Um dos primeiros sistemas automáticos de detecção de paroxismos desenvolvidos com a utilização de uma transformação nos domínios do tempo e da frequência foi publicado por Stelle e Comley [131], em 1990. Estes cientistas utilizaram a *Distribuição de Wigner*, que a exemplo da STFT, da WT e da MPT, também procura contornar os problemas do sinal de EEG analisando o sinal concomitantemente em tempo e em frequência, porém não utiliza o janelamento.

A Distribuição de Wigner (WD, em inglês) é calculada através de:

$$W_x(t, \omega) = \int_{-\infty}^{+\infty} x(t + \tau/2) \cdot x^*(t - \tau/2) \cdot e^{-j\omega\tau} \cdot d\tau \quad (\text{Eq. 4.2})$$

onde  $t$  é o tempo,  $\omega$  é a frequência e  $x^*(t)$  é o complexo conjugado do sinal  $x(t)$ .

Os CEO, objeto de estudo do trabalho de Stelle e Comley, aparecem no mapa 3D, que representa a DW, com uma forma de T, devido às componentes de frequência deste tipo de paroxismo.

A WD discreta também pode ser calculada através do algoritmo FFT e o custo computacional é aceitável. Porém, a WD perde em definição, em localização no tempo e na frequência para a WT e, por esta razão principalmente, foi abandonada em favor da utilização desta última.

#### 4.3.2 Detecção de DEs através da WT

Em 1997, Attellis *et al.* utilizaram a Transformada *Wavelet* Biortogonal para fazer a detecção de eventos epiléticos em EEGs [9], já que esta ferramenta permite uma melhor localização no domínio tempo-frequência, em relação à STFT, diferenciação entre os vários tipos de eventos epileptiformes e um custo computacional mínimo, se for utilizado um algoritmo rápido para o cálculo da transformada. O algoritmo utilizado neste trabalho foi introduzido por Unser *et al.*, em 1993, *apud* Attellis *et al.* [9].

Foi utilizada a função de escala *spline* cúbica:

$$\phi(t) = \begin{cases} 1 - |t| + \frac{1}{6}|t|^3 - \frac{1}{3}(1 - |t|)^3 & \text{se } |t| < 1 \\ \sqrt[6]{(2 - |t|)^3} & \text{se } 1 \leq |t| \leq 2 \\ 0 & \text{se } |t| > 2 \end{cases} \quad (\text{Eq. 4.3})$$

e a função *wavelet* correspondente:

$$\begin{aligned} \psi(t) = \frac{1}{40320} [ & -\phi(2t+6) + 124\phi(2t+5) - 1677\phi(2t+4) + 7904\phi(2t+3) \\ & - 18482\phi(2t+2) + 24264\phi(2t+1) - 18482\phi(2t) + 7904\phi(2t-1) \\ & - 1677\phi(2t-2) + 124\phi(2t-3) - \phi(2t-4) ] \end{aligned} \quad (\text{Eq. 4.4})$$

que garantem uma boa localização no plano tempo-frequência. Esta base *wavelet* será *biortogonal* [9][121][134][135] se existir uma função  $\tilde{\psi}(t)$  tal que

$$\langle \psi(2^{-j}t - k), \tilde{\psi}(2^{-j}t - l) \rangle = \begin{cases} 2^j, & \text{se } i = j \text{ e } k = l \\ 0, & \text{caso contrário} \end{cases} \quad (\text{Eq. 4.5})$$

e a família de funções  $\tilde{\psi}_{j,k} = \tilde{\psi}(2^{-j}t - k)$  é chamada de *base dual* de  $\psi_{j,k}$ .

O sinal de EEG é, então, expandido segundo as funções descritas acima, em seus coeficientes biortogonais  $d_j(k)$  e  $\tilde{d}_j(k)$  e a energia distribuída do sinal,  $e_j(r)$  é dada por:

$$e_j(r) = d_j(k) \cdot \tilde{d}_j(k) \quad (\text{Eq. 4.6})$$

para o nível de resolução  $j$  e para inteiros  $r$  no intervalo  $(k-1) \cdot 2^j < r \leq k \cdot 2^j$ .

A detecção de um evento epileptiforme se dá quando o valor de  $e_j(r)$  ultrapassa um determinado *threshold*  $D_j$ , definido para cada nível  $j$ .

A Figura 4.4 mostra um sinal de EEG decomposto segundo o algoritmo explicado acima e a detecção de um CEO.




Figura 4.4: (a) Sinal. (b) Detecção de um CEO, para os níveis de resolução  $j = 3$  e  $j = 5$ ; intervalo de tempo de 2 s. (Modificado de Detection of Epileptic Events in Electroencephalograms Using Wavelet Analysis [9])

## 4.4 Abordagens Híbridas

Todos os sistemas vistos até aqui podem ser considerados híbridos, de uma forma ou de outra, por utilizarem-se de mais de um tipo de ferramenta matemática ou computacional na análise dos sinais bioelétricos.

Porém, para efeitos de clareza, especificamente aqueles sistemas que utilizaram um ou mais tipos de análise por transformação, em conjunto a um ou mais tipos de análises de IA foram separados dos demais, nesta seção. Isto foi feito também porque a autora deste trabalho considera que a combinação das duas abordagens citadas acima (Transformações Matemáticas e Inteligência Artificial) forma a direção mais promissora a ser tomada para o desenvolvimento de ferramentas automatizadas de análise de sinais de EEG e gostaria de salientar as iniciativas que já foram tomadas neste sentido.

### 4.4.1 Detecção de DEs utilizando-se WT e Rede Feedforward

Com o objetivo de fazer a detecção automática de paroxismos no EEG, Kalayci e Özdamar [77], em 1995, propuseram a Transformada *Wavelet* como ferramenta de pré-processamento do sinal, a ser apresentado a uma rede neural. A questão que motivou o trabalho era: “Como apresentar os dados do sinal de EEG a uma rede neural? Na forma não-processada, que eles chamaram de ‘crua’ (isto é, segmentos do próprio sinal apenas digitalizado), ou na forma parametrizada, isto é, através de parâmetros extraídos do sinal, tais como, inclinação, amplitude, frequência, etc ?”

Como já foi visto em trabalhos anteriores apresentados neste capítulo, as opiniões dividem-se, já que os dois métodos oferecem vantagens e desvantagens.

Segundo os autores [77], com o EEG cru livre de artefatos, a detecção de paroxismos é mais simples, porém, há uma demanda por memória e por tempo computacional muito maior que nos dados parametrizados, onde segmentos do sinal são “descritos” por alguns parâmetros considerados relevantes para a análise e há considerável redução de dimensionalidade.

O maior problema da parametrização é justamente este: como determinar quais parâmetros são relevantes e suficientes para descrever-se um sinal, o qual varia consideravelmente de pessoa para pessoa?

Por esta razão, os pesquisadores pensaram em uma alternativa à utilização de dados parametrizados, mas com redução do volume de dados de entrada, para diminuição do custo



computacional: compactação de dados através de TW, para posterior apresentação destes coeficientes *Wavelet* à rede. Além disto o custo computacional do cálculo da TW pode ser extremamente reduzido através da utilização de algoritmos rápidos.

Os sinais de EEG para a implementação do sistema proposto pelos autores foram adquiridos de 5 pacientes (sistema 10-20 a 16 canais) sabidamente epiléticos e selecionados dentre aqueles que efetivamente apresentavam DEs. Os sinais foram filtrados na faixa de 1 a 70 Hz e digitalizados em 100 Hz (14 bits de resolução). Estes sinais foram levados a especialistas que selecionaram 761 segmentos contendo espículas e CEOs (segmentos SSW). Também foram escolhidos 2853 épocas contendo qualquer outro tipo de atividade, incluindo atividade de fundo e artefatos musculares (segmentos ñSSW). Em todos os segmentos SSW, a ponta principal da espícula foi posicionada no centro de uma janela de 5,12 s de largura, composta de 512 pontos. Nos segmentos ñSSW, um ponto aleatório do segmento foi centrado na mesma janela.

Em um segundo estágio do trabalho, os 3614 segmentos SSW e ñSSW foram transformados utilizando-se dois tipos de função *wavelet*: a Daubechies 4 (Db4) e a Daubechies 20 (Db20), para comparação posterior dos resultados. A transformada *Wavelet* de cada segmento de 512 pontos produziu 8 novos segmentos, referentes a cada uma das escalas de resolução  $a$  utilizadas na TW. Assim, o segmento da escala 1 representou a região de maiores frequências e foi descrito através de 256 pontos. O segmento de escala 2, com  $256/2 = 128$  pontos, representou a região de frequências imediatamente menores, e assim sucessivamente (vide Tabela 4.2).

Tabela 4.2: Janelas e Correspondentes Comprimentos de Onda. (Extraída de *Wavelet Preprocessing for Automated Neural Network Detection of EEG Spikes* [77])

Escala	Janela de Tempo (ms)	Largura de Banda (Hz)	
		Daubechies 4	Daubechies 20
1	160	21,76 – 50,00	21,00 – 50,00
2	320	9,48 – 21,76	8,84 – 21,00
3	640	4,12 – 9,48	3,72 – 8,84
4	1280	1,80 – 4,12	1,56 – 3,72
5	2560	0,78 – 1,80	0,65 – 1,56

O passo seguinte foi reconstituir o sinal a partir de determinadas combinações de escalas para determinar-se quais componentes são necessárias e quais componentes poderiam ser dispensadas na compactação dos dados de EEG, para análise de DEs. Obviamente as primeiras escalas, que abrangem as maiores frequências, são indispensáveis para que não se perca informação acerca dos paroxismos. Assim, após várias combinações avaliadas visualmente, chegou-se à conclusão que as três últimas escalas (6, 7 e 8, que continham 8, 4 e 2 coeficientes,

respectivamente) influenciavam muito pouco o formato dos eventos SSW e ñSSW, de modo que foram eliminadas.

Os coeficientes *wavelet* das cinco escalas de resolução restantes foram, então, utilizados para se gerar o conjunto de treinamento e o conjunto de teste para a RNA. Para isto, 8 pontos de amostras do EEG (quatro de cada lado do centro selecionado em cada época) foram tomados de cada escala de resolução, como mostrado na Figura 4.5. Devido à análise ser multiresolução estes oito pontos representaram janelas de diferentes durações no tempo, para cada escala diferente. A Tabela 4.2 também mostra a duração, em ms, de cada sub-janela de 8 pontos, para as diferentes escalas de resolução. Cada conjunto de treinamento e de teste foi formado através de uma combinação de escalas; por exemplo, um conjunto contendo oito coeficientes da escala 1 apenas, outro conjunto contendo 24 coeficientes das três primeiras escalas e assim por diante. Dos 3614 arquivos totais de dados, foram tomados aleatoriamente 1200 deles (400 de SSWs e 800 ñSSW) para treinamento e o resto foi utilizado para testes (361 SSW e 2053 ñSSW).




Figura 4.5: Representação multiescala da TW de (a) um CEO, e de (b) uma atividade de EMG, utilizando a *Wavelet* Daub-20. A figura mostra as 6 escalas superiores. As duas barras verticais nos sinais do alto abrangem 80 ms. Os oito coeficientes tomados de cada escala são indicados pelas setas. (Modificado de *Wavelet Preprocessing for Automated Neural Network Detection of EEG Spikes* [77].)

Desta forma, foi necessário criar-se várias RNAs, com diferentes dimensões de vetor de entradas, para se testar as várias combinações de coeficientes de escalas *wavelet*. A topologia da rede utilizada foi a *feedforward*, com algoritmo *backpropagation*, de  $n$  neurônios de entrada, 3 a 8 neurônios *hidden* e apenas um neurônio de saída. Este tinha a função de classificar o vetor de



entradas como SSW ou ñSSW. E os valores de *target* para estas classes foram arbitrados como 0,8 e -0,8, respectivamente. A função de ativação utilizada foi a tangente hiperbólica.

Cada rede foi treinada e testada duas vezes, e os melhores resultados foram tomados. Os valores de sensibilidade e especificidade para cada rede foram calculados através de  $TP.100 / (TP + FN)$  e  $TN.100 / (FP + TN)$ , respectivamente, onde *TP* é o número de classificações “positivas verdadeiras” de um SSW, *FN* é o número de “negativas falsas”, *FP*, de “positivas falsas” e *TN*, de “negativas verdadeiras”. A precisão global de cada rede foi assumida como uma média entre os valores de sensibilidade e especificidade.

Os resultados obtidos foram notáveis. Quando apenas uma escala (oito coeficientes) foi utilizada, a diferença de precisão de uma rede para outra variou drasticamente, dependendo da escala utilizada. Por exemplo, para as redes que utilizaram Db20, a escala 3 atingiu uma precisão de 90,2%, enquanto as redes que utilizaram as escalas 1 e 2 atingiram apenas uma precisão em torno de 50%, cada uma. Para as redes com Db4, a escala 1 atingiu valores de precisão melhores, em torno de 80%. Quando a escala 3 foi combinada a outras escalas obteve-se os melhores valores de precisão. A melhor classificação global (91,4%) foi obtida utilizando-se a função *wavelet* Db20 e a combinação das escalas 3 e 4 (16 coeficientes). Para as redes com Db4, a melhor combinação (90,8% de precisão) foi obtida com as escalas 1, 2 e 3 (24 coeficientes). Outro aspecto interessante dos resultados é que a variação do número de neurônios *hidden* não variou significativamente (em torno de  $\pm 2\%$ ) os resultados de precisão.

Todos estes resultados levam a conclusão que, sem variação significativa da precisão de classificação da rede neural, a escala de resolução *wavelet* 3, contendo apenas 8 coeficientes, pode ser utilizada com sucesso (90% de precisão, para Db20) como entrada para uma RNA de apenas 3 neurônios *hidden*, o que representa uma considerável economia computacional de tempo e memória de processamento. Além disto, a banda de frequência de 3,7 a 8,9 Hz pode ser assumida como representativa dos eventos epileptiformes para aqueles conjuntos de treinamento e teste. Os autores supõem que o baixo desempenho obtido com as escalas 1 e 2 esteja relacionado com a possível influência maior que estas sofreriam de artefatos de EMG. Concluíram também que a utilização das funções Db4 ou Db20 não influenciaram expressivamente nos resultados, com ligeira vantagem para a última.

Com o objetivo de também fazer-se uma comparação entre o método descrito aqui e a utilização pura e simples do sinal cru de EEG como entrada para RNAs, sem pré-processamento através da TW, épocas de 20 pontos (janelas de 100 ms) e de 30 pontos (janelas de 150 ms) foram utilizadas para treinar e testar redes neurais. Os resultados para estes tipos de entradas e para entradas utilizando as escalas 3 e 3+4, com Db4 e Db20, estão resumidos na Tabela 4.3.



Tabela 4.3: Valores Percentuais de Melhores Performances para RNAs. (Extraída de *Wavelet Preprocessing for Automated Neural Network Detection of EEG Spikes* [77]).

	20 ptos ñ-proces.	30 ptos ñ-proces.	8 ptos Db4	16 ptos Db4	8 ptos Db20	16 ptos Db20
<b>Sensibilidade</b>	91,1	93,1	82,0	89,1	87,3	90,8
<b>Especificidade</b>	95,9	94,3	89,9	91,8	93,3	93,2
<b>Precisão</b>	93,5	93,7	86,0	90,4	90,3	92,0

Considerando-se que o objetivo do estudo era diminuir o tamanho das RNAs de análise de EEGs (através da redução do comprimento dos vetores de entrada), sem diminuir consideravelmente a performance na detecção, os autores consideraram o trabalho válido, salientando antes, porém, que a seleção apropriada da escala, ou combinação de escalas *Wavelet*, é fundamental para atingir esta performance.

Uma última sugestão feita pelos autores [77] é que sejam investigadas as influências de outras funções no cálculo da TW, tais como as *wavelets* de Morlet ou *splines*, etc.

#### 4.4.2 Detecção de DEs utilizando-se HT e Rede Feedforward

Hoffmann *et al.* [68] propuseram a Transformada de Hilbert, em 1996, como ferramenta de pré-processamento e quantificação específica das características morfológicas e/ou topográficas da espícula *rolândica*, a qual ocorre freqüentemente nas regiões centro-temporais de crianças entre 3 e 16 anos de idade (na Epilepsia Parcial Benigna da Infância). A análise dos resultados obtidos com a Transformada de Hilbert ficou a cargo de uma RNA, para classificação *on-line*, tal como será descrito em seguida.

Como já mencionado no Cap. 3, a Transformada de Hilbert tem a propriedade de poder fornecer a parte imaginária de um sinal analítico, a partir da parte real conhecida do mesmo. O sinal analítico reconstituído, que no caso é o próprio sinal de EEG, foi então utilizado por Hoffmann *et al.* como base para o cálculo de duas outras séries temporais: *potência instantânea* - PI e *freqüência instantânea* - FI, as quais podem ser utilizadas na detecção de paroxismos do EEG.

A metodologia utilizada foi a seguinte: sinais de EEG foram adquiridos a partir de 27 crianças comprovadamente portadoras de Epilepsia Centro-Temporal Benigna da Infância. Foram utilizados 19 eletrodos dispostos no escalpo, sendo 2 eletrodos de referência média (orelhas), através do sistema 10-20. Os sinais foram digitalizados a 256 Hz e a filtragem foi feita através da própria transformada seletiva de Hilbert, na faixa de 4 a 30 Hz. Os sinais provenientes de 10 crianças foram reunidos em um grupo A, dos quais foram tomados intervalos de 10 min. subdivididos em segmentos de 2 s de duração, por EEG. Já os sinais oriundos das 17 demais

crianças foram segmentados de 3 em 3 s de duração, e destes segmentos calculou-se médias e selecionou-se um número variável de espículas, segundo um procedimento descrito por Uhl *et al.*, *apud* Hoffmann *et al.* [68].

O passo seguinte foi calcular o valor da *Potência de Campo Global* (PCG) [68], parâmetro este que permitiu definir-se o intervalo de análise dos paroxismos (época) em 60 ms: 20 ms para antes da ocorrência da espícula e 40 ms para depois.

A implementação da Transformada de Hilbert deu-se através de duas formas. Através da FFT (vide referência [63] – Relação entre Hilbert e Fourier) de  $N = 512$  pontos: Transformada de Hilbert relacionada ao intervalo (TH1), que foi utilizada para processamento dos sinais do grupo A e através de um algoritmo de cálculo *on-line* da TH (TH2), testado para o grupo B.

O cálculo das séries temporais PI e FI através de TH1, para o grupo A, foi realizado para os segmentos de 2 s que apresentavam espículas e a saída de todos os canais de cada segmento formou um mapa referente à distribuição espacial de valores de PI e FI de cada canal, para um determinado instante de tempo [68]. Nos mapas de PI a ocorrência de espículas focais manifestou-se como valores altos de potência instantânea, bem localizados. Já nos mapas de FI verificou-se uma estabilização da frequência de descargas neuronais em patamares constantes de 7 a 18 Hz, durante a ocorrência dos paroxismos. Os mapas topográficos de PI foram, então, classificados visualmente em 7 diferentes grupos, segundo o tipo de distribuição espacial e localização da potência máxima. Três grupos ( $K_1, K_2, K_3$ ) referiam-se à potência máxima localizada no hemisfério esquerdo, três outros grupos ( $K_4, K_5, K_6$ ), no hemisfério direito e um grupo ( $K_7$ ), na região do vértex, eletrodos Cz, Pz. A Figura 4.6 ilustra o comportamento das séries temporais PI e FI frente à ocorrência de uma espícula e a aparência dos mapas topográficos.

Finalmente, construiu-se uma RNA *feedforward*, com algoritmo de treinamento *backpropagation* para “ler” os sinais de cada canal de entrada e classificá-los segundo uma das classes de paroxismos epileptogênicos acima descritas ou em outras duas classes de não-epileptogenicidade. Dez mapas PI típicos de cada uma das 7 classes de SSW e das 2 classes de não-SSW foram selecionados visualmente de 5 das crianças do grupo A, para o conjunto de treinamento, resultando em 90 padrões de treinamento. Portanto, a rede neural possuía 17 neurônios de entrada, um para cada eletrodo posicionado no escalpo, 12 neurônios na camada *hidden* e 9 neurônios de saída, um para cada possível classe.

Foram formados dois conjuntos de testes, TS1 e TS2. O conjunto TS1 foi constituído de oito mapas normalizados para cada classe tomados das demais 5 crianças do grupo A. O conjunto TS2 utilizou os 17 segmentos médios do grupo B, calculados com TH2.






Figura 4.6: 1 - Análise do canal C4 baseada em TH1. As linhas verticais indicam o intervalo de análise (60 ms) para a segunda espícula presente no sinal. (A) Sinal no canal C4 - amplitudes -  $S$  designa o *threshold* para uma detecção de espícula (empiricamente estimado), (B) Série temporal PCG; (C) Série temporal PI de (A); (D) Série temporal FI de (A). 2 - Sequência de mapas PI durante o intervalo de ocorrência da segunda espícula, no segmento mostrado em 1(A). Cada mapa está normalizado entre os valores mínimo e máximo da amostra. (Modificado de *Analysis and classification of interictal spike discharges in benign partial epilepsy of childhood on the basis of the Hilbert transformation* [68])

Os resultados foram bastante satisfatórios e se observou que a HT é uma ferramenta “suficiente e eficiente para caracterizar a morfologia da espícula” [68] (sinais com duas ou três inversões de polaridade, CEO, onda rápida, etc.) e também que a rede neural foi capaz de classificar corretamente 63 dos 72 mapas topográficos de TS1, sendo que das classificações incorretas, apenas uma foi um falsa-negativa (sensibilidade igual a 98%) e as 5 demais foram falsas-positivas pertencentes às classes  $K_8$  e  $K_9$  (seletividade = 92,6%). Já nos testes *on-line* do conjunto TS2 obteve-se 100% das classificações corretas.

Dois outros trabalhos já haviam sido publicados a respeito da utilização da HT como ferramenta de processamento do sinal de EEG, por membros da equipe de Hoffmann e outros pesquisadores, em 1990 [145] e em 1991 [146]. Porém a utilização de uma RNA para fazer a classificação dos mapas topográficos foi um trabalho inédito de Hoffmann *et al.* [68].



## 4.5 Outros Sistemas

É importante mencionar que outros sistemas de detecção automática de eventos foram também estudados por utilizarem as ferramentas de Inteligência Artificial e Transformação, as quais são objetos de interesse neste trabalho. Estas ferramentas são Redes Neurais MAK [80][82] e *Feedforward*, Transformadas *Matching Pursuit* [36], *Karhunen-Loève* e Pacotes *Wavelet* [28][29][140], Regras de Produção Antropomimétricas, Máquina de Estados Finitos, Lógica Fuzzy, etc. No entanto, estes sistemas não foram detalhados neste capítulo por não serem dedicados ao reconhecimento de espículas e sim de ritmos cerebrais, estágios do sono ou estados mentais em EEG [41][60][31][32][43][76][111][107], ou por não serem aplicados à análise de sinais de EEG, mas sim de sinais de EMG [44] ou mesmo de imagens de ultrassom [122].

De qualquer forma, cada um destes trabalhos trouxe alguma contribuição à compreensão dos sinais de EEG ou das ferramentas que se pretendia utilizar neste trabalho, de maneira que podem ser citados como referências.

## 5. METODOLOGIA DO TRABALHO

Em tendo sido estabelecida toda a fundamentação teórica, este Capítulo dedicar-se-á à apresentação formal do trabalho desenvolvido: as etapas de análise de requisitos, projeto e prototipagem do SIDAPE, Sistema de Detecção e Análise de Paroxismos Epileptiformes, em sinais de EEG.

### 5.1 Escopo do Problema

Estabeleceu-se como escopo a ser abordado pelo sistema automático:

“O SIDAPE receberá arquivos digitalizados contínuos, provenientes de um sistema de aquisição digital comercial e fará o particionamento dos mesmos em segmentos de 15 segundos (vide a Seção 5.4) para facilitar o armazenamento individual de cada segmento em arquivos de memória. Estes arquivos serão recuperados e processados seqüencialmente pelo SIDAPE, gerando arquivos de saída com informações sobre a possível ocorrência de paroxismos em cada um deles. Em um segundo momento, o SIDAPE recuperará os arquivos contendo as épocas do sinal e as informações de ocorrência de DEs e os utilizará para apresentar uma saída já com as detecções realizadas pelo sistema ao revisor (eletroencefalografista).”

Este escopo está ilustrado na Figura 5.1.

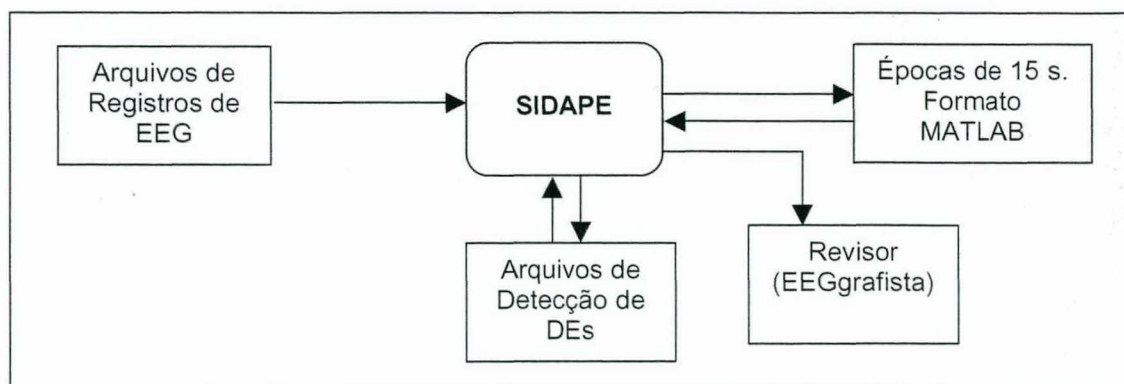


Figura 5.1: Diagrama de Contexto do Sistema SIDAPE. O sistema recebe dados contínuos de EEG digitalizados, organiza-os em segmentos de 15 segundos de registro e a partir destes gera arquivos contendo as informações de detecção. Os arquivos de 15 segundos e de detecção são posteriormente utilizados para apresentação gráfica dos resultados ao revisor.

Entretanto, uma vez definidos os requisitos e o escopo para o sistema e antes que se pudesse partir para a etapa de projeto foi necessário definir a origem do banco de dados a ser utilizado no trabalho.

## 5.2 A Base de Dados

Não se tem conhecimento de um banco de dados de sinais de EEG relacionados à Epilepsia, comercialmente disponível. E ainda que houvesse, o mais conveniente seria que se pudesse utilizar dados cuja procedência exata fosse conhecida e, além disto, que estes fossem confiáveis, adquiridos e processados segundo as necessidades e exigências do trabalho. Isto significa que se deve poder escolher as fontes humanas dos dados (que tipo de paciente, com que tipo de epilepsia, com que idade, etc.), o modo de registro do EEG (sistema 10-20 ou não, registro unipolar ou bipolar, número de eletrodos, número de canais, etc.), a forma de pré-tratamento do sinal (qual a banda de filtragem utilizada para eliminar o nível DC e os artefatos), etc, o que é impossível de se fazer a não ser que se possa montar o próprio banco de dados.

A universidade da Finlândia disponibiliza alguns dados sobre epilepsias de ausência generalizadas, tônico-clônicas generalizadas e psicomotora, no endereço: <http://www.ai.univie.ac.at/oefai/nn/anndee/data.html>. Porém estes dados encontram-se bastante corrompidos por ruídos musculares, com saturações de amplitude e só fornecem 4 canais, o que não seria suficiente para uma análise adequada, como já foi discutido.

Após contatos com várias instituições e clínicas de Epilepsia no Brasil, conseguiu-se permissão do Montreal Neurological Institute (MNI) para obtenção de dados de pacientes comprovadamente epiléticos, bem condicionados e em quantidade suficiente para que se pudesse desenvolver, treinar e testar o sistema.



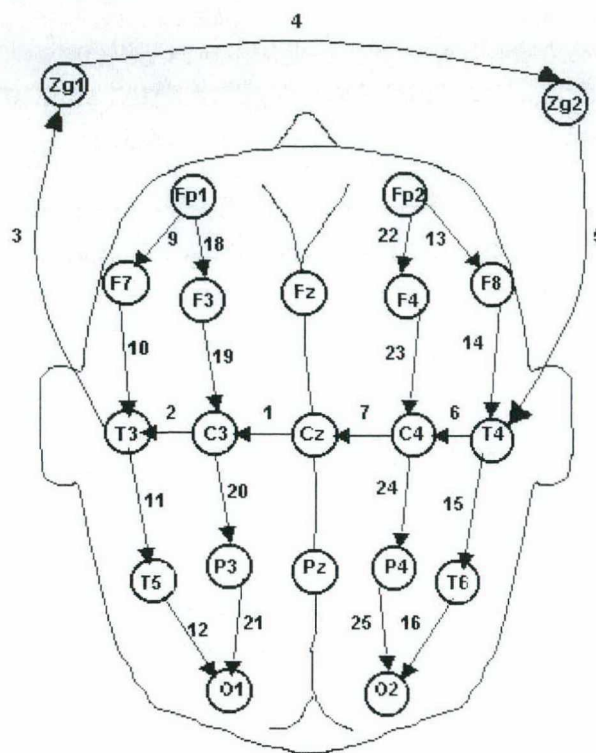
Foram obtidos 9 registros de EEG, adquiridos a partir de 7 pacientes adultos, escolhidos dentre os pacientes internados na Clínica Neurológica do MNI, no período entre 30 de maio e 10 de junho de 1999. A partir da monitoração de longo termo destes pacientes, foram selecionados os 9 registros de durações variáveis (quatro registros de 60 minutos de duração, quatro registros de 90 minutos de duração e um registro de 120 minutos de duração, totalizando 12 horas de registro de EEG). O critério para seleção dos trechos de registro foi que estes coincidisse com manifestações eletrográficas epileptogênicas significativas de forma que os registros contêm grande quantidade de espículas (alguns milhares nos 9 registros), de ondas agudas *sharp* e, em dois destes, crises epiléticas eletroencefalográficas. A seleção dos pacientes e dos 9 trechos foi realizada por duas revisoras de EEG do próprio MNI. Os sinais foram amostrados a 100 Hz, em horários variados para que se pudesse obter dados de pacientes em distintos estados comportamentais e períodos sono-vigília, em 32 canais (com exceção de um dos registros, o qual foi adquirido em 24 canais) e montagens bipolares do tipo zigomática-temporal (“*Zygo-Db-Temp*” - eletrodos nas posições Zy1, Zy2, Fp1, Fp2, F3, F4, F7, F8, F9, F10, CZ, C3, C4, T3, T4, T5, T6, T9, T10, P3, P4, P9, P10, O1, O2 e dois eletrodos para EOG: Eogl e Eogr) (Figura 5.2). Os sinais foram pré-filtrados analogicamente no sistema de aquisição Harmonie, da Stellate Systems®, CA, em uma banda de 0,5-40 Hz. Não foram realizadas filtragens digitais adicionais. Maiores informações sobre os sinais poderão ser obtidas no Anexo C.

Paralelamente, as espículas dos sinais já adquiridos foram sendo marcadas (e classificadas como “Perfeitas” ou “Comuns”<sup>15</sup>) nos registros pelos Drs. Jean Gotman e Felipe Quesney, na companhia da autora do trabalho e como parte do treinamento da mesma em leitura de espículas em EEG. Ao final do treinamento, as marcações foram sendo feitas pela própria autora e posteriormente conferidas pelo Dr. Jean Gotman.

Estas marcações foram utilizadas, posteriormente, na implementação e nos testes do sistema.

---

<sup>15</sup> Rótulos utilizados para qualificar o quanto a espícula aproxima-se da morfologia padrão, descrita na bibliografia. Note-se que sistemas tais como [139] e [106] também utilizaram classificações similares.



### ZYGOMATIQUE-TEMPORALE

Figura 5.2: Um tipo de montagem zigomática-temporal bipolar utilizando 25 eletrodos arranjados em 32 canais (derivações bipolares marcadas com números ao lado das flechas). Os números ao lado das setas identificam as derivações bipolares. Os eletrodos Zg1 e Zg2 (ou Zy1 e Zy2) são posicionados nos maxilares.

Os registros individualizados por códigos de identificação de paciente foram armazenados nos formatos: binário (este contendo todas as marcações de espículas e crises realizadas pelo sistema Harmonie<sup>®</sup>, pelas revisoras do MNI, pela autora do trabalho e pelo Dr. Jean Gotman) e de texto, em Compact Disc (CD-ROM). Rotinas de decodificação, leitura e representação gráfica foram implementadas no Brasil.

Os arquivos selecionados para futura utilização na implementação e testes do SIDAPE foram organizados da seguintes forma (cada arquivo contendo 32 canais e duração de 15 segundos):

#### *Arquivos com Espículas e Ondas Agudas:*

- Paciente1 (“lap”) – 35 arquivos, com espículas no lobo temporal, bilateral;
- Paciente2 (“wam”) – 29 arquivos, com espículas nos lobos frontal e temporal direitos;
- Paciente3 (“sr”) – 36 arquivos, com espículas e CPEO generalizados;
- Paciente3, 2º. registro (“sr2”) – 27 arquivos, com espículas, CPEO e CEO de 3 Hz generalizados;

- Paciente4 (“vad1”) – 29 arquivos, com espículas nos lobos frontal e temporal direitos;
- Paciente4, 2º. registro (“vad2”) – 53 arquivos, com espículas nos lobos frontal e temporal direitos;
- Paciente5 (“zog”) – 13 arquivos, com espículas em todo o hemisfério esquerdo;
- Paciente6 (“kur”) – 25 arquivos, com espículas nos lobos frontal e temporal, bilaterais e forte crise eletrográfica no lobo temporal-occipital direito;
- Paciente7 (“jok”) – 41 arquivos, com espículas e CPEO em todo o hemisfério esquerdo e crise eletrográfica.

*Arquivos com Ruídos Musculares de grandes amplitudes:*

- Paciente1 (“lap”) – 5 arquivos;
- Paciente4 (“vad1”) – 2 arquivos;
- Paciente4, 2º. registro (“vad2”) – 2 arquivos;
- Paciente5 (“zog”) – 1 arquivo;
- Paciente6 (“kur”) – 1 arquivo;
- Paciente7 (“jok”) – 6 arquivos.

*Arquivos com Piscadas perfeitas:*

- Paciente1 (“lap”) – 1 arquivo;
- Paciente2 (“wam”) – 2 arquivos;
- Paciente3 (“sr”) – 3 arquivos;
- Paciente3, 2º. registro (“sr2”) – 3 arquivos;
- Paciente4 (“vad1”) – 6 arquivos;
- Paciente4, 2º. registro (“vad2”) – 6 arquivos;
- Paciente6 (“kur”) – 8 arquivos;
- Paciente7 (“jok”) – 1 arquivo.

*Arquivos com ritmo Alfa evidenciado:*

- Paciente1 (“lap”) – 8 arquivos.



*Arquivos com ritmo Delta evidenciado:*

- Paciente3, 2º. registro (“sr2”) – 2 arquivos;
- Paciente6 (“kur”) – 1 arquivo.

*Arquivos com Fusos do sono:*

- Paciente1 (“lap”) – 4 arquivos;
- Paciente4 (“vadI”) – 1 arquivo;
- Paciente5 (“zog”) – 7 arquivos.

*Arquivos com Complexos K:*

- Paciente5 (“zog”) – 1 arquivo.

Dentro de cada um destes arquivos, os eventos mais claros e perfeitos (espículas, ritmos alfa, ruídos, piscadas, etc, considerados óbvios e com formatos próximos aos padrões descritos em Atlas – vide Seções 2.3.1, 2.3.2 e 2.3.3) foram mais uma vez selecionados e listados para utilização posterior no treinamento e testes das RNAs e testes com a FWT e com o sistema, tal como será descrito na sequência.

### **5.3 Arquitetura Geral do Sistema**

Nesta seção serão apresentados os módulos construtivos principais do SIDAPE, a saber, blocos de Transformação, Análise Neural e base de Regras e como foram integrados, em definitivo.

O diagrama de blocos da Figura 5.3 ilustra, em um nível de abstração mais alto, as etapas de processamento no SIDAPE, sem considerar as interfaces ao usuário e à memória. O detalhamento dos módulos e etapas de processamento será feito na sequência.

Em linhas gerais, este processamento é realizado no SIDAPE da seguinte maneira:

O registro de EEG adquirido do paciente, durante um certo período de monitoração, é dividido em arquivos de memória de computador de 15 segundos de duração, para posterior armazenamento, processamento, recuperação e apresentação gráfica. E cada canal destes arquivos de 15 segundos é analisado separadamente pelo sistema, conforme ilustra a Figura 5.4.

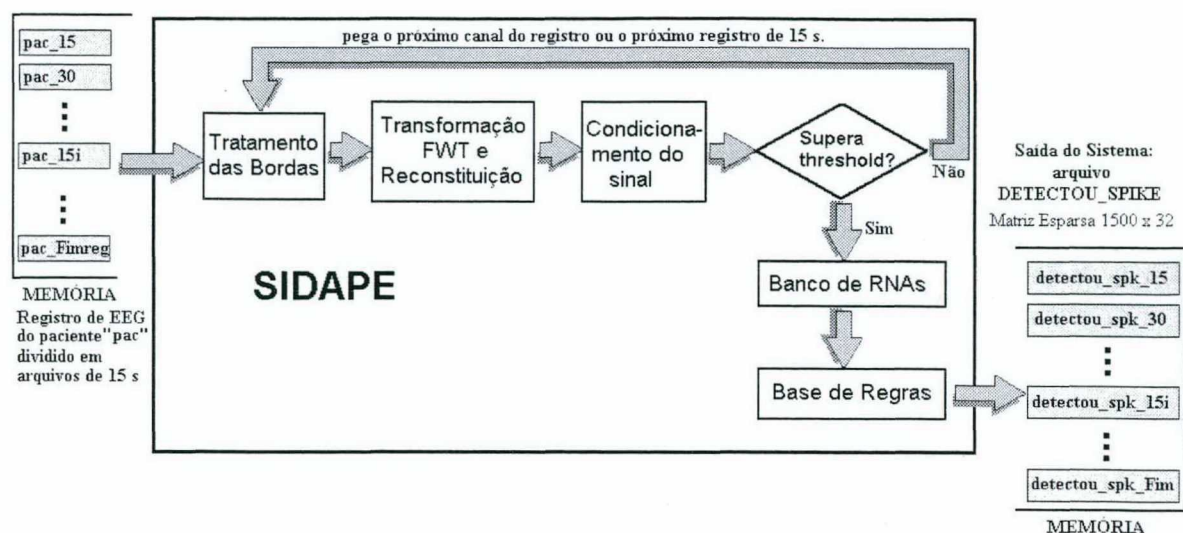


Figura 5.3: Diagramas de Módulos do SIDAPE.




Figura 5.4: Separação dos canais dos registros de EEG realizada na entrada do SIDAPE.



Cada canal sofre um tratamento nas bordas, para que as discontinuidades nos pontos inicial e final não gerem distorções após a transformação e, por consequência, falsas detecções (vide Figura 5.7 da Seção 5.5).

O vetor de pontos de cada canal (com 1500 pontos) é transformado por meio da FWT, com a função *wavelet* Coiflet 1 e até o 3º. nível de decomposição (Figura 5.5). Imediatamente após é realizada a transformada inversa (vide Seção 5.6.5) onde são mantidos apenas os sinais reconstituídos a partir das componentes de detalhe da decomposição, nos níveis 1, 2 e 3 (Figura 5.5).

Em seguida, os 3 vetores de detalhe para cada um dos 32 canais são submetidos a várias rotinas de condicionamento (vide Seção 5.7), onde são normalizados e tem suas médias e desvios-padrões calculados (Figura 5.5).

É realizada então a secção de cada um destes vetores em 15 janelas de 1 segundo (com 100 pontos amostrados), por canal. Ou seja, cada arquivo de 15 segundos transforma-se em 15 vetores de 1 segundo de duração e de 100 elementos, antes de ser entregue às etapas de processamento posteriores (Figura 5.5).

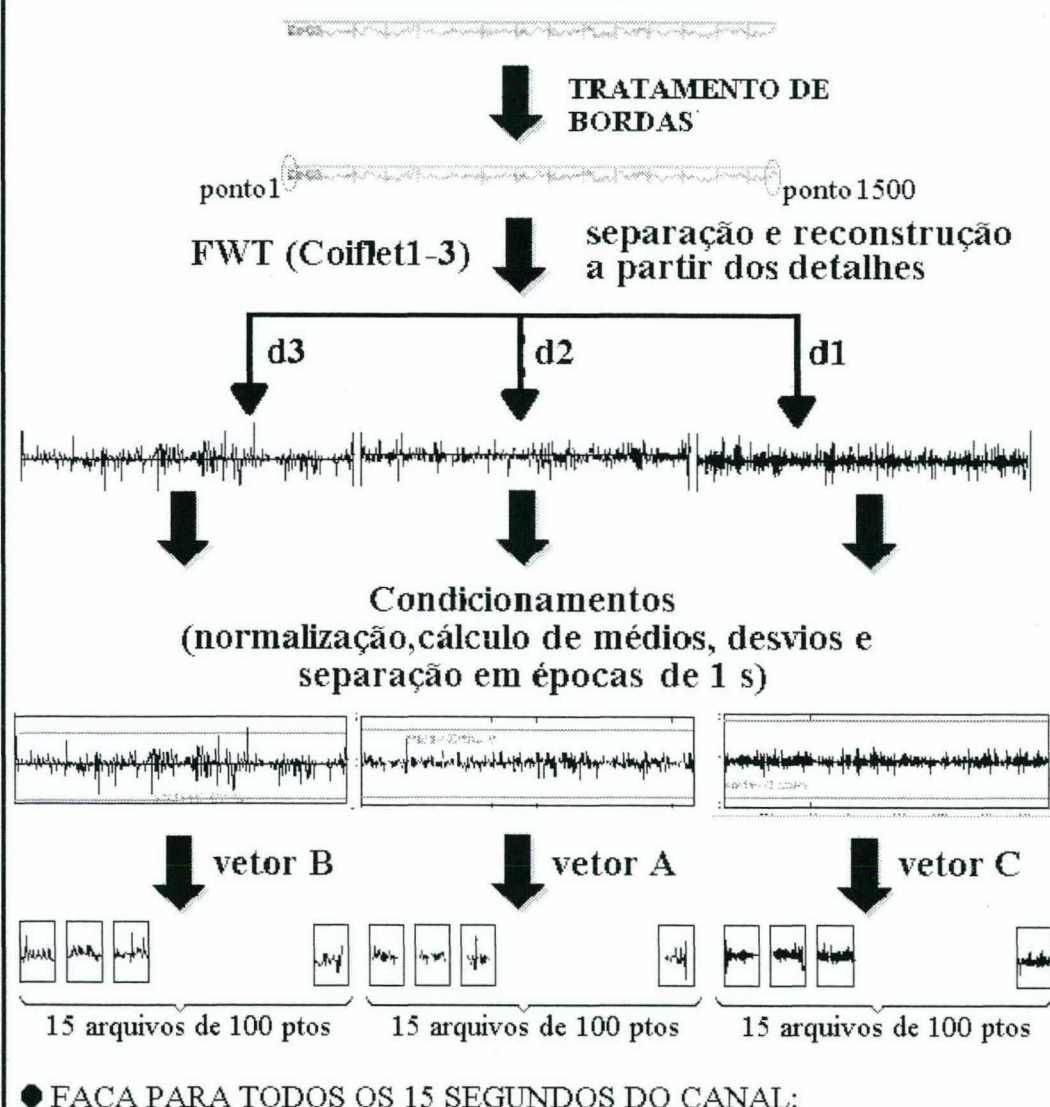
Finalmente, ainda dentro do Módulo de Condicionamento, calcula-se o valor de máximo absoluto para cada um destes sinais reconstituídos (o qual deve coincidir com o pico referente à espícula, se houver paroxismos na época, na maior parte das vezes) e verifica-se se este ultrapassou um *threshold* fixo de 7,5 desvios-padrão além da amplitude média para aquele vetor de detalhe, naquele segundo e para aquele canal. Caso isto não tenha ocorrido, o programa inicia a análise do próximo vetor, no próximo segundo, no canal atual (ou no próximo canal, caso os 15 segundos do canal atual já tenham sido analisados). Caso tenha havido superação dos limiares, os vetores são submetidos à análise por redes neurais (Figura 5.5).

As próximas etapas do SIDAPE são ilustradas na Figura 5.6. O vetor derivado da componente detalhe 2 (denominado de vetor A) é apresentado à rede que detecta eventos do tipo Espículas e Ondas Agudas (RNA 1). O sinal reconstituído a partir da componente detalhe 1 (vetor C) é apresentado à rede que detecta paroxismos do tipo Ruídos Musculares (RNA 3). E o sinal advindo da componente detalhe 3 (vetor B) é utilizado tanto em uma segunda rede utilizada para detecção de Espículas e Ondas Agudas (RNA 2), quanto na rede neural que detecta Piscadas e outros Movimentos Oculares epileptiformes (RNA 4). As saídas das redes são ponderadas e processadas por um conjunto de Regras de Produção de IA, o qual fornecerá a decisão, propriamente dita, acerca da ocorrência de um *spike*. Esta decisão terá valor binário igual a 0 ou 1 e será armazenada na variável matriz esparsa *detectou\_spike*. A seguir, o programa passa à análise da próxima época de 1 segundo, canal a canal, até o final do arquivo atual de 15 segundos, e assim



por diante, até o final do registro. O arquivo de saída *detectou\_spk\_15i*, referente à análise do *i*-ésimo arquivo de 15 segundos do registro, é armazenado em memória para posterior utilização nas interfaces de apresentação dos resultados.

● FAÇA PARA TODOS OS CANAIS DO ARQUIVO:



● FAÇA PARA TODOS OS 15 SEGUNDOS DO CANAL:

```

Se | Máx(epoch(SegundoAtual))A,B,C > Média(SegundoAtual)A,B,C + 7.5*Desvio(SegundoAtual)A,B,C
    AnáliseNeural(epoch(SegundoAtual))
Fim Se
  
```

Figura 5.5: Esquemas de tratamento de bordas, transformação *Wavelet*, reconstrução, condicionamento e separação de épocas de 1 segundo para cada canal analisado. Ao final, o sistema verifica se o *threshold* foi ultrapassado e envia a época, caso afirmativo, para a etapa de Análise Neural.

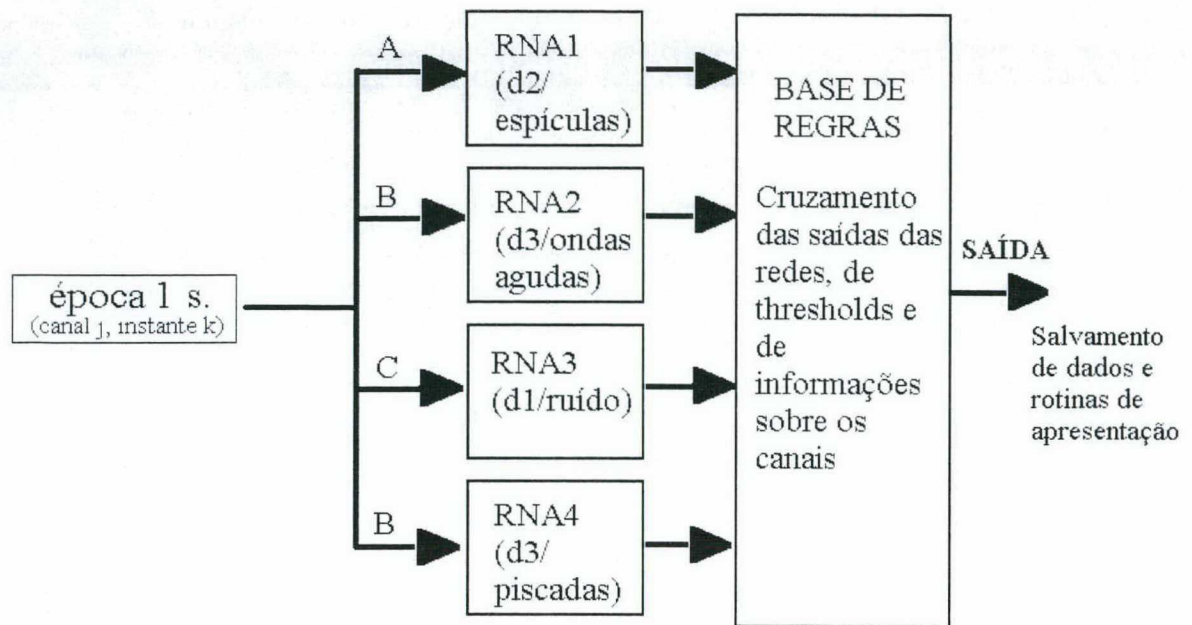


Figura 5.6: Caso o valor de máximo na época de 1 segundo tenha ultrapassado o *threshold* (Média + 7.5 Desvios-padrão), este será submetido a um grupo de quatro Redes Neurais Artificiais, cada uma treinada para reconhecer um tipo específico de evento. As saídas das redes serão analisadas por um Base de Regras, com o objetivo de fornecer uma saída sobre a possibilidade de ocorrência de uma espícula na época.

Na sequência cada módulo e cada método será detalhado.

## 5.4 Arquivos de 15 segundos

Optou-se por dividir os registros de EEG em períodos de tempo menores e em canais para facilitar o processamento dos mesmos em computador. Por exemplo, um registro de 1 hora de dados (sem as informações sobre registro, montagens e paciente) gravado no formato binário comprimido do Harmonie (\*.eeg) ocupa aproximadamente 65 Mbytes de memória, com os sinais adquiridos em 100 Hz. Já em formato texto, o espaço aumenta para 120 Mbytes, aproximadamente. Ora, o carregamento e o processamento deste montante de dados em um programa dedicado rodando em Desktop PC demandaria dispositivos de armazenamento e recuperação dos dados especiais (CD-ROMs e discos ópticos de grandes velocidades e principalmente, grande quantidade de memória RAM), fundamentalmente se os registros fossem de longo termo. Particionando-se estes registros, pode-se executar o processamento e a recuperação rapidamente e de forma sequencial, sem grande demanda por *hardware*.

A escolha por telas de 15 segundos foi feita com base na característica de comportamento estacionário do EEG para períodos curtos de tempo, como 20 segundos [2][144]. Para o caso de haver revisores usuários do sistema que prefiram janelas de 30 segundos para leitura, a implementação da abertura de 2 arquivos ao mesmo tempo para processamento pelo sistema é simples. Os arquivos de 15 segundos, contendo apenas pontos amostrados do EEG em 32 canais, no formato binário do MATLAB® (precisão de 8 bits/amostra, sem compressão), ocupam 414 kbytes (90 Mbytes para 240 arquivos totalizando 1 hora de registro), enquanto os que possuem apenas 24 canais ocupam 320 kbytes.

## 5.5 Tratamento das Bordas

A Transformada *Wavelet* Rápida (FWT), assim como a FFT, calcula cada elemento dos vetores de coeficiente a partir de um conjunto de elementos de índices imediatamente anteriores e/ou posteriores ao mesmo. Estes pontos anteriores e posteriores são utilizados de forma ponderada para obter-se o valor do coeficiente para o ponto atual (vide ANEXO A).

Sempre que isto ocorre é necessário utilizar-se algum procedimento de tratamento das bordas dos vetores, pois estas não dispõem de pontos anteriores – no caso da borda à esquerda, ou posteriores – no caso da borda à direita, para que se possa efetuar o cálculo adequado dos valores atuais. A implicação disto é que a FWT distorcerá os valores nas bordas dos vetores de EEG. Sobretudo, se os pontos de borda tiverem valores relativamente discrepantes da média do vetor completo, a FWT interpretará este evento como um transiente e irá gerar um pico no vetor transformado, que poderia ser interpretado pela Rede Neural como uma espícula (Figura 5.7). Esta é uma das razões pelas quais deve-se evitar fracionar excessivamente os canais a serem analisados: a cada vez que se segmenta um vetor e o submete a uma FWT, dois novos pontos distorcidos serão adicionados ao canal transformado.

Existem diversos algoritmos e métodos específicos para tratamentos das bordas. Para o sistema SIDAPE optou-se por transformar todo o vetor de 15 segundos de cada canal de uma só vez e só depois fracioná-lo a cada 1 segundo para análise pela Rede Neural. Isto permite que só existam possíveis distorções nos pontos inicial (índice = 1) e final (índice = 1500) dos 15 segundos de cada canal. O raciocínio aplicado para o tratamento das bordas foi:

*SE ABS(sinal[1]) > MEDIA(sinal) ENTÃO Sinal[1] = sinal[2] FIM SE e*  
*SE ABS(sinal[1500]) > MEDIA(sinal) ENTÃO sinal[1500] = sinal[1499] FIM SE*






Figura 5.7: Acima: Sinal de EEG com descontinuidades abruptas nos pontos de bordas (índices 1 e 1500). Abaixo: Sinal transformado com distorções (marcadas com elipses) nas bordas, devido às descontinuidades no tempo.

Ou seja, quando o valor absoluto do ponto de borda (utiliza-se a função módulo  $\text{ABS}()$  para tomar tanto picos positivos quanto negativos) for maior que o valor de média para aquele canal (é um valor discrepante, de certa forma) o algoritmo faz o ponto de borda ter valor igual ao seu sucessor (no caso da borda à esquerda), ou antecessor (no caso da borda à direita).

O procedimento acima foi ilustrado na Figura 5.7 como a linha tracejada nas bordas à esquerda ( $\text{senal}[1] = \text{senal}[2]$ ) e à direita ( $\text{senal}[1500] = \text{senal}[1499]$ ).

A grande desvantagem em se desconsiderar dois pontos do vetor de EEG, em 1500, é que se por coincidência existirem uma ou duas espículas neste sinal, com máximos exatamente nestes índices, estas serão sumariamente cortadas do sinal e por conseqüência não poderão ser detectadas. A probabilidade que isto ocorra, no entanto, é obviamente menor que a probabilidade de existência de valores discrepantes nas bordas, portanto acredita-se que valha a pena incorrer neste erro.

## 5.6 Módulo de Transformação Rápida *Wavelet*

### 5.6.1 *Porque a Transformada Wavelet*

Esta seção descreve porque a Transformada *Wavelet* foi considerada a mais adequada na utilização em implementação de um sistema automático de detecção de espículas em EEG.

Os tópicos podem ser sumarizados da seguinte maneira:

- *Flexibilidade*: A Transformada *Wavelet* pode, a princípio, ser aplicada a qualquer tipo de série temporal, como um sinal digitalizado de EEG e utilizar qualquer tipo de função<sup>16</sup> como *kernel*, ou *wavelet-mãe*. Isto permite que a função escolhida seja aquela com uma alta correlação em relação ao sinal desejado, o que deve aumentar a eficiência da detecção;
- *Redução da Dimensionalidade*: decorrente do tópico anterior, tem-se a propriedade de compressão dos dados<sup>17</sup> que a Transformada *Wavelet* oferece. Tanto por permitir a escolha do *kernel*, quanto por um aspecto inerente ao algoritmo da FWT: a *subamostragem* ou *decimação*. Ou seja, se a aplicação permitir a utilização dos coeficientes obtidos na FWT (e não o sinal reconstruído a partir de algumas componentes) o tamanho dos vetores utilizados terá, no máximo, a metade do comprimento do vetor do sinal original;
- *Existência de um algoritmo rápido*: talvez possa ser comprovado, no futuro, que algum outro tipo de Transformada seja mais apropriado à análise de sinais bioelétricos. No entanto, até o momento, um dos poucos tipos de Transformada que possui um algoritmo rápido (e um dos mais velozes computacionalmente) é a Transformada *Wavelet*. E isto faz uma considerável diferença quando o processamento do sinal será feito por meio de *softwares* executados em computadores pessoais, sobretudo se o objetivo é uma análise *on-line*.

<sup>16</sup> É desejável que a função atenda às restrições já descritas na seção 3.2.3, ou que seja modificada para tal. Porém várias funções *Wavelet*, como a Haar por exemplo, satisfazem apenas alguns dos requisitos.

<sup>17</sup> Por exemplo: uma onda dente-de-serra, muito utilizada em aplicações industriais e de eletrônica, amostrada a 256 observações por segundo, é representada compactamente por meio de 16 componentes *wavelet*. Já uma análise de Fourier do mesmo sinal exigiria 256 tipos de senóides, devido à dificuldade técnica em representar descontinuidades da FT [23].

- *Grande disponibilidade de bibliografia de referência:* devido às suas interessantes particularidades, a Transformada *Wavelet* despertou grande interesse nas comunidades científicas do mundo inteiro e nas áreas mais variadas (comunicação digital, monitoramento remoto, astronomia, geologia, análise numérica, codificação e representação de dados, compressão de sinais, imagens e matrizes, supressão de ruídos, processamento de sinais e imagens dos mais variados tipos, etc [23]). Com tantos engenheiros e cientistas interessados, a gama de estudos, leituras, observações e descobertas sobre a ferramenta cresceu muito rapidamente, de forma que hoje a disponibilidade de referências bibliográficas é vasta (o que nem sempre acontece com as ferramentas de Transformação criadas mais recentemente) e isto torna a ferramenta mais acessível e facilita sua compreensão;
- *Grande disponibilidade de aplicativos de software:* Da mesma forma, vários *softwares* de manipulação e/ou análise *Wavelet* foram desenvolvidos nos últimos anos. Alguns, inclusive, de domínio público (vide Anexo B). Para o presente trabalho, foi utilizado o pacote de ferramentas, ou *Toolbox*, da plataforma Matlab 5.0<sup>®</sup>, o qual dispunha de quase todas as funções relacionadas à implementação *wavelet* que se poderia necessitar;
- *Relativa facilidade de utilização:* apesar de envolver uma teoria matemática relativamente pesada e complexa, a utilização da Transformada *Wavelet*, principalmente no que diz respeito ao algoritmo rápido é muito simples e está bastante documentada, ao contrário de outros tipos de Transformada.

Tendo em vista estas questões, optou-se então pela utilização da FWT neste trabalho.

### **5.6.2 Aplicação da FWT no trabalho**

Uma das grandes dúvidas surgidas ao longo do trabalho foi sobre a utilização de dados sem pré-processamento ou parametrizados, como entradas para as Redes Neurais classificadoras.

O sinal sem processamento de EEG não fornece dados em uma forma que qualquer sistema computacional desenvolvido até hoje possa interpretá-los. No entanto, um especialista treinado em eletroencefalografia consegue compreender e extrair importantes informações a partir dos mesmos dados.

Por outro lado, os dados parametrizados facilitam a análise por parte dos computadores, mas obviamente toda a informação que não foi parametrizada e que pode ou não conter conhecimentos adicionais acerca dos eventos epileptogênicos será desprezada sumariamente. Na



tentativa de uma maior aproximação do discernimento humano (mais eficiente em classificação de padrões que a máquina) optou-se por utilizar os dados não-parametrizados como entradas do sistema. Porém, com uma particularidade: os mesmos serão condicionados e pré-processados por uma transformação, visando ressaltar os eventos epileptogênicos dos demais e assim facilitar a análise posterior, tal como o especialista humano também faria. Normalmente, pesquisadores utilizam mesmo transformar, através de FFT por exemplo, os sinais bioelétricos que pretendem analisar. Assim, o Módulo de Transformação FWT tem como objetivos representar o mesmo sinal de EEG de uma forma mais simples e clara para que seja mais fácil interpretá-lo, mesmo por um especialista humano, aumentar a relação sinal/ruído, através da diminuição da influência de componentes com frequências mais altas e evidenciar ao máximo os eventos espiculares no sinal, de forma a facilitar o trabalho subsequente das RNAs. A Figura 5.8 ilustra como as componentes de detalhe ressaltam os eventos, em relação à atividade de fundo, nos sinais de EEG.

Porém, como já foi bastante discutido nos capítulos anteriores, esta capacidade que se esperava da FWT dependia fundamentalmente do grau de correlação entre os eventos espiculares e a base de funções *wavelet* a ser utilizada. Ou seja, quanto maior fosse a semelhança entre uma espícula e a função *wavelet*, maiores seriam os valores de amplitude dos coeficientes de decomposição *wavelet*, calculados com base na correlação entre o sinal e a função e maior seria o grau de compactação na decomposição. E esta escolha teria que ser feita de forma sistemática, para garantir bons resultados.

### 5.6.3 Primeira Abordagem para o Problema de Escolha da Função Wavelet

A primeira idéia para se chegar a uma função *wavelet* que tivesse máxima semelhança com uma espícula padrão foi a de derivar uma expressão para uma função *wavelet* a partir da própria espícula. Então tentou-se a aplicação do algoritmo "*Optimal Matched Wavelet*" (ou "*Wavelet Assemelhada Ótima*"), desenvolvido por Chapa e Rao [25][26][110], o qual é capaz de derivar a função *wavelet*-mãe a partir do próprio padrão que se pretende ressaltar no sinal, no caso as espículas, com o objetivo de maximizar a correlação entre o sinal de interesse e a função *Wavelet*.

Porém, o algoritmo leva em conta alguns princípios matemáticos para realizar esta derivação, os quais são as condições para a utilização de uma base como Conjunto *Wavelet* (Admissibilidade, Conservação de Energia e Regularidade, vide seção 3.2.3).




Figura 5.8: (a) Registro original de 32 canais durante 15 segundos, no alto. (b) Registro onde todos os canais foram transformados utilizando-se a função *Wavelet* Coiflet 1 e reconstruídos apenas a partir da componente de detalhe 1. Notar como o ruído nos canais 4 e 5 foi evidenciado. (c) Registro onde todos os canais foram transformados utilizando-se a função *Wavelet* Coiflet 1 e reconstruídos apenas a partir da componente de detalhe 2. Notar como as espículas (principalmente nos 7º e 8º segundos de registro) foram ressaltadas.



No entanto, o fato destas restrições serem utilizadas no algoritmo fez gerar uma função *wavelet morfolologicamente* distante do padrão espicular, o que é o objetivo contrário do trabalho. Ou seja, a função *wavelet* derivada através do algoritmo é a função *wavelet ideal* (isto é, permite uma Transformada Inversa, é normalizada, oferece suporte compacto e menor redundância na decomposição), mais próxima matematicamente de uma espícula-onda, mas não é a função *wavelet* morfolologicamente mais próxima desta. Mais especificamente, a função *wavelet*-mãe do algoritmo de Chapa e Rao sempre oscila suavemente e tem valor médio igual a zero, enquanto que, numa espícula de EEG as discontinuidades e transitórios são presentes e a integral deste padrão normalmente tem valor relativamente alto (possui uma componente DC). Como resultado, quando se tentou decompor um sinal de EEG com presença de espículas, utilizando-se a função *wavelet* derivada do algoritmo de Chapa e Rao, a correlação foi mínima e os eventos espiculares não foram ressaltados da atividade de fundo.

Acredita-se que caberia uma nova investigação mais minuciosa desta metodologia, no futuro. A despeito desta possibilidade, talvez fosse interessante estudar-se também a flexibilização do algoritmo de Chapa e Rao, para que se obtenha não apenas funções *wavelet* ideais, mas que se possa abrir mão de algumas das restrições para atender os objetivos de uma aplicação específica, tal como é feito em vários tipos de funções *wavelet* conhecidas, como a Haar, por exemplo.




Figura 5.9: Exemplo de aplicação do algoritmo “Optimal Matched *Wavelet*”, de Chapa e Rao [26]. (a) Padrão Espícula-Onda, claramente positivo, com altas frequências na região das espículas e com pico de grande amplitude; (b) Função *Wavelet* derivada através do algoritmo, com oscilações suaves, amplitude média nula e sem projeção do pico referente à espícula.



### 5.6.4 Metodologia empregada para Escolha da Função Wavelet

Após extensivo trabalho de pesquisa bibliográfica e consultas à Internet (inclusive ao jornal eletrônico “*Wavelet Digest*”, editado por Wim Sweldens da Lucent Technologies, Laboratórios Bell – [www.wavelet.org](http://www.wavelet.org)) e apesar da grande quantidade de trabalhos de estudo da WT sendo realizados, concluiu-se que não havia outro algoritmo que formalizasse a definição da função *Wavelet* mais adequada a uma aplicação específica. Até o presente momento, esta escolha era aleatória ou empírica. Inclusive alguns especialistas consideram que, a princípio, qualquer função poderia ser utilizada para qualquer propósito, sem diferenças significativas nos resultados, conceito do qual discorda a autora deste trabalho dadas as inúmeras distinções (em suporte, em regularidade, em morfologia, em ordem de decomposição, em ortogonalidade, simetria, etc) existentes entre as várias funções utilizadas atualmente (vide, como exemplo, a Figura 5.10).

Em sendo assim, pensou-se em se desenvolver uma metodologia própria, de escolha da função *wavelet* existente mais adequada aos propósitos deste trabalho, ao invés de se tentar criar uma nova função. Ou seja, com base em uma metodologia simples [6] tentou-se determinar, senão a função *wavelet* “ótima” para análise de DEs, dentre as mais utilizadas no meio científico, pelo menos uma que ofereça um alto grau de correlação morfológica com as espículas.




Figura 5.10: Acima: trecho de sinal de EEG com Complexo Espícula-Onda ao centro. Abaixo à esquerda: função senoidal utilizada pela FFT para decomposição. Abaixo à direita: função *Wavelet* Symlet de ordem 4, claramente mais próxima morfológicamente do padrão Espicular que a senóide.

A idéia básica por trás da metodologia foi exatamente aproveitar o fato de que a Transformada *Wavelet* consegue ressaltar os eventos interessantes nos sinais de EEG, em relação à atividade de fundo (vide, por exemplo, a Figura 5.8). Ou seja, o sinal de EEG decomposto por

FWT em escalas apropriadas, de modo geral, apresenta a resposta à espícula com amplitude expressivamente maior que as respostas correspondentes às demais atividades do EEG. O objetivo da metodologia era determinar qual a função *wavelet*, dentre as mais utilizadas atualmente, que mais ressaltaria estas espículas, em relação aos outros eventos do EEG. Em outras palavras, dado o comportamento de filtro passa-bandas das funções *wavelet* aplicadas aos sinais, qual a função *wavelet* que mais amplificaria a banda de freqüências relacionada às espículas, que é a de interesse neste trabalho (Figura 5.11).




Figura 5.11: A tarefa de escolher a função *Wavelet* mais adequada para detecção de espículas pode ser interpretada, no domínio da freqüência, como encontrar aquela função cuja banda passante amplificaria mais as componentes de freqüência das espículas e ondas agudas.

A metodologia foi fundamentada em conceitos da Estatística básica e algumas experimentações, quais sejam:

#### **Axioma:**

“Seja uma variável aleatória contínua independente  $X$ . Se a função densidade de probabilidade (fdp) de  $X$ ,  $f(x)$ , puder ser aproximada pelo Modelo de Distribuição Normal (*Gaussiano*) ou seja,  $X : N(\mu, \sigma^2)$ , onde  $\mu$  é o valor médio de  $X$  e  $\sigma^2$  é o valor de variância para o conjunto  $X$ ; então pode-se afirmar que [24]:

- A probabilidade de ocorrência de um evento em  $X$ , com valor compreendido no intervalo de  $[-2\sigma + \mu, 2\sigma + \mu]$  é de 95,45% (onde  $\sigma$  é o desvio-padrão);

- A probabilidade de ocorrência de um evento em  $X$ , com valor compreendido no intervalo de  $[-4\sigma+\mu, 4\sigma+\mu]$  é de 99,99%.”

Portanto, a probabilidade de ocorrência de um evento em  $X$  dependente, isto é, devido à variável  $X$ , e com valor maior ou menor que 4 Desvios-Padrão acima e abaixo da Média pode ser considerada nula.

A partir desta afirmativa, assumiu-se:

- a atividade de fundo normal de um sinal de EEG digitalizado como sendo uma *variável aleatória contínua independente*;
- a atividade epiléptica de um sinal de EEG como sendo *outra variável aleatória contínua independente* e, portanto, um “evento discrepante” passível de ocorrer simultaneamente à atividade elétrica normal do cérebro;
- a distribuição de freqüências de um sinal digitalizado de EEG normal como *tendendo* ao Modelo Normal<sup>18</sup> (Figura 5.12), ou seja, com maior número de observações de valores de amplitudes médias e com raras observações de valores de amplitudes extremas;
- a fdp das componentes *Wavelet* do vetor de EEG, após uma transformação, também seguirá o modelo Normal.




Figura 5.12: Distribuições de freqüências do registro de EEG “jok\_15.mat” (32 canais), com média zero e envelope próximo à Distribuição Normal

Caso as assertivas acima possam ser aceitas, pode-se concluir que:

<sup>18</sup> Sabe-se que a princípio qualquer função densidade de probabilidade de qualquer variável aleatória pode ser aproximada pela Distribuição Normal. E de fato, a posteriori comprovou-se mediante experimentos com Distribuições de freqüências de vários sinais de EEG, que os “envelopes” destas distribuições seguem o “comportamento” de uma curva Gaussiana, ligeiramente assimétricas e com médias próximas de zero (Figura 5.12). Vale lembrar que o sinal digitalizado de EEG é discreto e a curva Normal, contínua. Porém, com o número de observações (tamanho do vetor de EEG) tendendo a infinito, a distribuição de freqüências aproxima-se mais da curva normal.



Se a variável “Atividade de Fundo normal em EEG” e a variável “Atividade Elétrica proveniente de Distúrbio ou Foco Epiléptico” são independentes entre si, a FWT de um sinal de EEG deveria gerar valores esperados (médias) e dispersões (variâncias) diferentes para ambas as variáveis (o que de fato ocorre, já que as amplitudes no tempo atribuídas às atividades epileptogênicas normalmente têm valores mais elevados e comportamentos mais “regulares” que a atividade de fundo, normalmente desorganizada e com aspecto semelhante ao ruído branco -Figura 5.10, no alto);

Variando-se as funções *wavelet*-mãe, para a transformação *Wavelet* de cada sinal de EEG poder-se-ia verificar, através da medida de Desvio-Padrão, “qual” *wavelet*-mãe estará mais “próxima” matematicamente da atividade epileptogênica. Isto porque uma função *wavelet* altamente correlacionada ao padrão de espículas (e menos, em relação à atividade normal, que é independente) deverá gerar valores mais elevados de dispersão nos pontos de ocorrência da atividade discrepante, que nos demais pontos (associados à atividade de fundo).

Para comprovação das proposições acima, foram selecionados 18 arquivos, de 15 segundos cada, contendo sinais de EEG, de pacientes comprovadamente epiléticos, dentre aqueles obtidos junto ao MNI.

Destes 18 arquivos, 9 contam com espículas que podem ser chamadas de “Perfeitas” e 9, com espículas denominadas “Ordinárias” (com morfologias contaminadas por outros tipos de eventos, como ruídos, ondas lentas, movimentos oculares, etc, tal como acontece mais freqüentemente nos registros).

Para realizar a transformação *Wavelet*, foram selecionadas as funções *wavelet*-mãe mais utilizadas atualmente, as que possuíssem melhores propriedades de regularidade, suporte compacto, possibilidade de reconstrução, simetria, filtros FIR, momentos de decaimento, etc [121] e que, sobretudo, guardassem alguma semelhança com a morfologia de um evento tipo espícula (maior correlação).

As funções *Wavelet* utilizadas foram:

Biortogonais: 1.1, 1.3, 1.5, 2.2, 2.4, 2.6, 2.8, 3.1, 3.3, 3.5, 3.7, 3.9, 4.4, 5.5, e 6.8;

Coiflets: 1, 2, 3, 4 e 5;

Daubechies: 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19 e 20;

Symlets: 2, 3, 4, 5, 6, 7 e 8

Os números acima se referem às ordens dos filtros dos quais dispõe cada função *wavelet*. As funções biortogonais utilizam o filtro de reconstrução diferente do filtro de decomposição e por

isto a notação diferenciada: o número antes do ponto refere-se à ordem do filtro de reconstrução (transformada inversa) e o número após o ponto, à ordem do filtro de decomposição.

Além disto, para cada uma destas 47 funções aplicadas a cada um dos 18 sinais com espículas calculou-se a FWT com variação discreta da escala  $s = 1, \dots, 2^5$  (cinco operações de decomposição = cinco componentes para cada sinal decomposto, através de cada função). Isto porque, empiricamente e também através de escritos correlatos [77] já era sabido que os sinais de EEG dificilmente apresentam componentes *wavelet* significativas para análise de paroxismos após uma escala 5, tal como exemplifica a Figura 5.13.




Figura 5.13: Ordenadas - amplitudes em microVolts. Abscissas – tempo em segundos. Transformação FWT de um sinal  $s$  (no alto) em 6 níveis de decomposição e posterior reconstituição a partir das componentes. As espículas-onda (segundos 3 e 6) foram evidenciadas, em relação aos demais eventos existentes no registro, nas componentes de detalhe 2 e 3 (maiores variações de amplitude em relação às amplitudes médias). As componentes a partir do nível de decomposição 5 trazem pouca informação relevante acerca do sinal de EEG e o sinal reconstruído a partir da componente de detalhe 1 contém informação clara sobre o ruído no início do sinal  $s$ .



Para cada uma destas decomposições, foi calculado o sinal recomposto de 15 segundos (transformada inversa), de forma a isolar no tempo as componentes para cada escala  $s$  e cada função *wavelet*-mãe. E sobre estes sinais reconstruídos, calculou-se o desvio, ponto-a-ponto.

As funções *wavelet*-mãe que não puderam oferecer valores de 4 desvios-padrão além da média (valores discrepantes) ou superiores, para nenhum valor de escala e em sinais que possuísem eventos espícula foram eliminadas (bior1.1, bior1.3, bior1.5, haar e db19).

As funções *wavelet*-mãe que geraram desvios-padrão maiores que 4, porém para eventos outros que não as espículas (como por exemplo, o próprio transitório das bordas do sinal – vide seção 5.5), também foram eliminadas (bior6.8, db6, db9 e sym6).

Um algoritmo foi também criado para verificar se os índices dos valores discrepantes de cada arquivo coincidiram com o ponto exato de ocorrência de uma espícula, ou estavam contidos em um intervalo de 4 pontos, centrado no ponto de ocorrência da espícula<sup>19</sup>. A partir destes dados, gerou-se uma série de 18 tabelas, contendo, para cada uma das 47 funções *wavelet*:

- Valor de desvio máximo encontrado no sinal reconstruído, a partir de cada componente;
- Índice de ocorrência do máximo (para verificação de coincidência);
- Escala onde ocorreu o máximo;
- O desvio máximo encontrado na escala 2 (normalmente a escala onde as espículas parecem mais acentuadas, em relação à atividade de fundo);
- O índice de ocorrência do máximo, para a escala 2.

O procedimento foi repetido também para arquivos com duração de apenas 4 segundos (2 antes, 1 durante e 1 após a ocorrência da espícula), de forma a “concentrar” a análise em torno das espículas. Os resultados obtidos foram ainda mais consistentes e os valores de desvio-padrão obtidos no instante de ocorrência das espículas, para grande parte das funções *wavelet*-mãe, ultrapassou 8 Desvios-padrão, além da média.

Todas estas informações foram cruzadas, como será detalhado na sequência e chegou-se, finalmente, a duas funções *wavelet*-mãe que se destacaram consideravelmente das demais: a *Biortogonal 2.2* e a *Coiflet 1*. A tabela abaixo sumariza os resultados obtidos, dentro dos critérios de avaliação estabelecidos, apenas para as 11 funções *Wavelet* que forneceram melhores resultados:

---

<sup>19</sup> Algumas bases wavelet provocaram atrasos de fase no sinal transformado, gerando estas diferenças nos índices do sinal antes e após a transformação. Porém, quando a diferença foi expressiva, o ponto de máximo desvio foi considerado como não tendo sido gerado pela espícula e foi desprezado.



Tabela 5.1: Resultados finais da Análise

	<i>1P</i>	<i>5P</i>	$\geq 8$	$\geq 10$	<i>Tt1</i>	<i>Pto</i>	<i>Ld</i>	<i>Dv</i>	$\frac{N}{E}$	<i>Tt2</i>	<i>Tt3</i>
<b>Bior2.2</b>	4	14	12	5	<b>49</b>	11	3	1	3	<b>10</b>	<b>59</b>
<b>Bior2.4</b>	3	11	8	3	<b>34</b>	10	5	3	0	<b>12</b>	<b>46</b>
<b>Bior2.6</b>	1	12	11	3	<b>34</b>	8	4	5	0	<b>7</b>	<b>41</b>
<b>Bior2.8</b>	0	8	9	1	<b>20</b>	10	4	3	2	<b>9</b>	<b>29</b>
<b>Bior4.4</b>	0	7	7	1	<b>17</b>	10	5	2	1	<b>12</b>	<b>29</b>
<b>Bior5.5</b>	0	1	4	0	<b>5</b>	7	4	7	0	<b>4</b>	<b>9</b>
<b>Coif1</b>	7	16	14	5	<b>59</b>	11	4	1	2	<b>12</b>	<b>71</b>
<b>Coif2</b>	0	6	10	3	<b>25</b>	9	4	5	0	<b>8</b>	<b>33</b>
<b>Db2/</b>	0	7	10	0	<b>17</b>	7	4	6	1	<b>4</b>	<b>21</b>
<b>Sym2</b>											
<b>Db3/</b>	3	5	8	3	<b>28</b>	7	6	5	0	<b>8</b>	<b>36</b>
<b>Sym3</b>											
<b>Sym4</b>	0	3	6	2	<b>15</b>	10	3	4	1	<b>8</b>	<b>23</b>
<b>TOTAL</b>	18	90									

Onde:

1P – Número de vezes em que a base gerou o maior valor de desvio, além da média e para o ponto de ocorrência exato da espícula;

5P – Número de vezes em que a base ficou entre as 5 que geraram maiores valores de desvio, além da média e para o instante correto;

$\geq 8$  – Número de vezes em que a base gerou valores de desvio-padrão superiores a 8 além da média, para um determinado nível de decomposição e para o instante correto;

$\geq 10$  – Número de vezes em que a base gerou valores de desvio-padrão superiores a 10 além da média, para um determinado nível de decomposição e para o instante correto;

Pto – Número de vezes em que um ponto de maior desvio em relação à média para a base *wavelet* coincidiu exatamente com o ponto (índice) de ocorrência (maior amplitude absoluta, em módulo) da espícula, para um determinado nível de decomposição;

Ld – Número de vezes em que um ponto de maior desvio em relação à média para a base *wavelet* ficou imediatamente adjacente ao ponto (índice) de ocorrência da espícula, para um determinado nível de decomposição;

Dv – Número de vezes em que um ponto de maior desvio em relação à média para a base *wavelet* ficou próximo ( $\pm 3$  pontos, no máximo, à direita ou à esquerda), porém não imediatamente adjacente com o ponto de ocorrência da espícula, para um determinado nível de decomposição;

NB – Número de vezes em que um ponto de maior desvio em relação à média para a base *wavelet* não coincidiu, absolutamente, com o instante de ocorrência da espícula, para um determinado nível de decomposição.

Apenas para efeito de comparação foram arbitradas três equações com pesos diferentes para cada um dos parâmetros descritos nas colunas da tabela e de forma que se pudesse chegar a uma decisão final. Assim:

Tt1:

$$Total\ 1 = (1P \times 2) + (5P \times 1) + (>8 \times 1) + (>10 \times 3) \quad (Eq. 5.1)$$

Tt2:

$$Total2 = (Pto + Lado) - (Dív + NB) \quad (Eq. 5.2)$$

Tt3:

$$Total3 = Total1 + Total2 \quad (Eq. 5.3)$$

Com relação a qual valor de escala  $s$  onde o sinal de espícula ficaria mais ressaltado, em relação aos demais, encontrou-se que os níveis 2 e 3 foram os mais freqüentes portadores de maiores valores de desvio. Com ligeira vantagem para o nível 2, já que o nível 3 foi mais sensível a eventos dos tipos artefatos de EOG e movimentos lentos do paciente, presentes no EEG. Por outro lado o nível 3 foi capaz de captar ondas agudas *sharp* mais freqüentemente que o nível 2 (Figura 5.17). Já o nível 2 foi o mais “localizado” no tempo (gerou menos atrasos de fase nos sinais reconstruídos), permitindo uma maior certeza acerca da coincidência do pico gerado após a transformação, em relação à espícula.

### 5.6.5 Saídas do Módulo de Transformação

Considerando-se os experimentos acima, adotou-se a função *Wavelet* Coiflet 1, nos níveis de decomposição 2 e 3 para processar os sinais  $s_{ij}$  e gerar os sinais reconstituídos  $A = FWT^1[d_2]$  e  $B = FWT^1[d_3]$  como entradas para as duas RNAs Classificadoras de Espículas (Figura 5.14).

Também, como será visto posteriormente, observou-se empiricamente que eventos no EEG relacionados a movimentos oculares (cuja banda de freqüências é localizada abaixo da banda das espículas, normalmente) eram maximizados no vetor de detalhes 3. Por esta razão, o sinal reconstruído  $B$  foi aproveitado como entrada para uma Rede Neural treinada para o reconhecimento de ruídos por movimento ocular, piscadas, etc.






Figura 5.14: Diagrama de Blocos do Módulo de Transformação do SIDAPE.

Já os eventos no EEG devidos a artefatos quaisquer (de paciente, de equipamento, por interferências externas, etc) apresentaram maiores concentrações de energia no vetor de detalhes 1, principalmente por serem compostos por frequências localizadas acima da banda das espículas, normalmente. Então um sinal reconstruído  $C = FWT^{-1}[d_1]$  foi utilizado no treinamento de uma Rede Neural para Reconhecimento de Ruídos.




Figura 5.15: Trecho de sinal de 1 segundo de EEG, com espícula à direita (acima) e os sinais reconstruídos a partir dos vetores de coeficientes detalhe 2 e detalhe 3 (abaixo). Notar como o sinal obtido a partir do detalhe 2 praticamente mantém apenas a espícula, em relação ao resto dos eventos. Já o sinal obtido do detalhe 3 apresenta-se mais “serrilhado”.






Figura 5.16: Acima: sinal com espícula-onda a partir dos 400 ms do segmento. Abaixo: sinais reconstruídos a partir dos vetores de detalhe 2 e 3. O sinal obtido do detalhe 3 teve máxima amplitude absoluta exatamente no ponto correspondente ao pico da espícula, porém apresentou excessivo *ripple*, o que dificultaria o trabalho da rede de reconhecimento e diferenciação. Ou seja, o sinal obtido do detalhe 2 localizou melhor a espícula.




Figura 5.17: Acima: Sinal de EEG com onda aguda, ao centro. Abaixo: apenas o sinal derivado da componente de detalhe 3 foi capaz de ressaltar a onda *sharp*.

As figuras acima ilustram alguns dos resultados obtidos com a utilização dos componentes de detalhe na análise de espículas em EEG. Já a Figura 5.18 fornecerá uma noção dos conteúdos de frequência do sinal, após a transformação e reconstrução e mostrará o efeito de filtro passa-banda da FWT sobre os sinais.

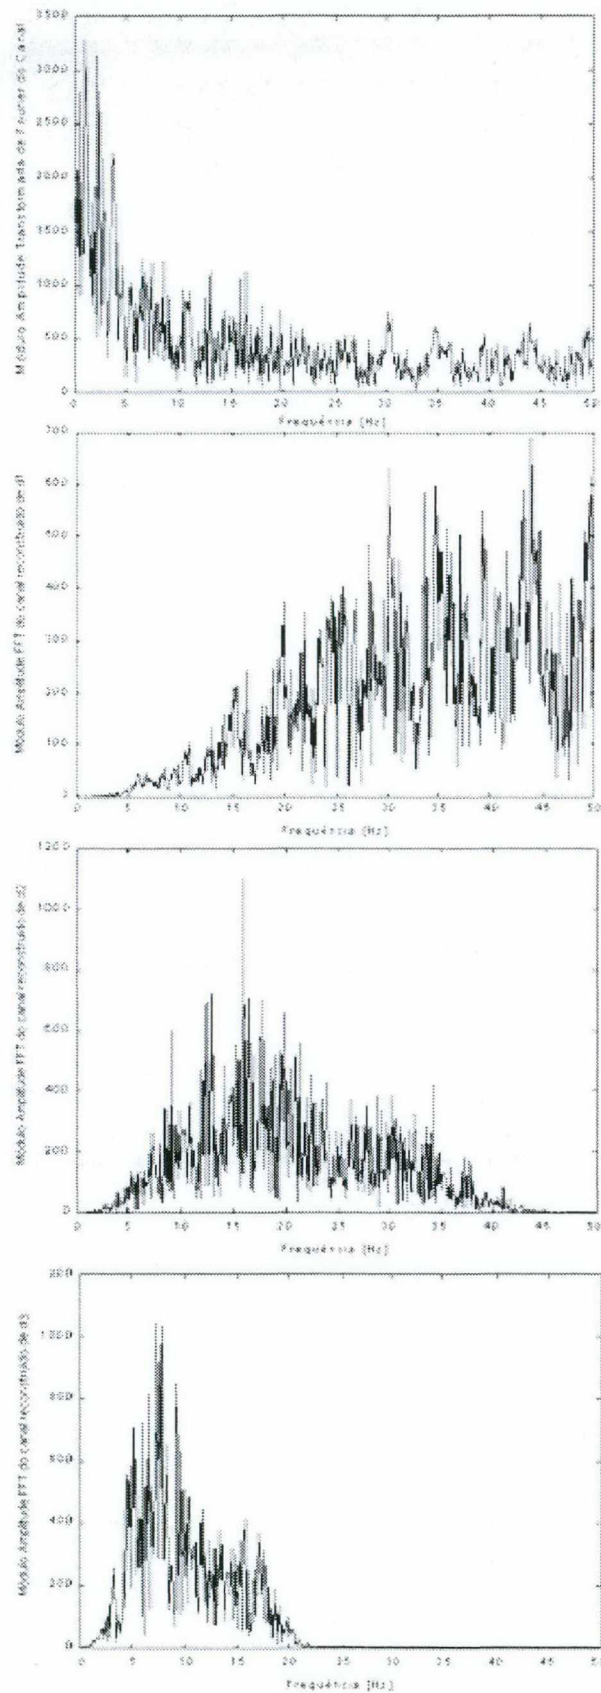


Figura 5.18: De cima para baixo - Investigação os conteúdos de frequência, via FFT, do sinal  $s$  da Figura 5.13 e dos sinais reconstruídos a partir das componentes de detalhe 1, detalhe 2 e detalhe 3.

## 5.7 Condicionamento dos Sinais

O objetivo que se almejava alcançar com o uso da FWT foi atingido na maior parte das vezes (vide Figura 5.15 e Figura 5.16); qual seja, gerar vetores de sinais com altas amplitudes apenas durante a ocorrência de espículas e eliminar a maior parte das influências devidas a outros tipos de eventos. Porém, alguns aspectos de ordem quantitativa dificultaram a análise direta dos sinais reconstruídos por parte das RNAs.

Um destes problemas é a grande variabilidade da faixa de amplitudes que podem ocorrer em um EEG. Dependendo do estado físico e comportamental do paciente, as amplitudes poderiam variar entre  $-25 \mu\text{V}$  e  $+25 \mu\text{V}$  (predominância da banda beta e alfa) ou chegar a oscilações da ordem de  $-500 \mu\text{V}$  e  $+500 \mu\text{V}$ , como em casos de movimentos musculares de grande intensidade.

Ficou bastante difícil treinar as RNAs de forma que estas pudessem reconhecer espículas com amplitude máxima desde 20 até 200  $\mu\text{V}$  e fazê-las diferenciar estes eventos de picos de ruído com amplitudes das mais variadas.

### 5.7.1 Normalização dos sinais

A saída lógica, portanto, seria a normalização. Porém não se conseguiu um valor fixo de fator de normalização que se pudesse aplicar a todos os sinais. Por exemplo, se todos os arquivos tivessem suas amplitudes divididas por um fator igual a 100, os paroxismos de baixas amplitudes seriam praticamente anulados. Se os arquivos fossem divididos por 20, por exemplo, quase não se conseguiria diminuir eventos com amplitudes exageradas.

Então, a alternativa encontrada foi normalizá-los em função do conteúdo de amplitudes que cada trecho analisado possuísse.

Ou seja, cada sinal A, B e C é normalizado em função da sua amplitude máxima absoluta, de forma que todos os sinais apresentados às redes tenham valores no intervalo  $[-1, +1]$ , o que possibilitou os treinamentos e testes posteriores com as redes neurais.

### 5.7.2 Cálculo de Média e Desvio-Padrão

Como já foi visto na seção 5.6.4, a Transformada *Wavelet* Coiflet 1 permitiu que eventos epileptiformes fossem bastante ressaltados em relação aos demais eventos do EEG. E de um modo geral, as amplitudes destes picos enfatizados normalmente ultrapassou 8 desvios-padrão acima das médias de amplitudes para os sinais analisados. Na Tabela 5.1, por exemplo, pode-se notar que dos 18 sinais utilizados, 14 tiveram picos acima de 8 desvios com o uso da Coiflet 1, no ponto exato de



ocorrência da espícula do sinal original. Partindo-se desta propriedade, assumiu-se o valor empírico de 7,5 desvios-padrão acima da média para considerar um pico dos sinais reconstruídos como candidato à espícula.

Assim, os sinais A, B e C têm seus valores relativos de média e desvio-padrão calculados, para que se possa compará-los, em cada trecho, com o *threshold* de 7,5 desvios nos procedimentos seguintes (Figura 5.19).




Figura 5.19: O SIDAPE toma os sinais reconstruídos a partir da FWT e calcula suas médias e desvios-padrões. Após isto, o ponto máximo em cada época é calculado e estimado em número de desvios além da média. As linhas cinza marcam o *threshold* para amplitudes de 7,5 desvios acima de cada média. Notar que no sinal reconstruído a partir do detalhe 2, apenas o pico (com amplitude igual à média mais 9 desvios-padrão) referente a uma espícula do sinal original (circundada no alto) superou o *threshold*.

### 5.7.3 Épocas de 1 segundo

Durante o desenvolvimento do trabalho, foram testados vários tamanhos de épocas para processamento *Wavelet* e Neural. Desde janelas com duração semelhante a de um *spike* (i.e., aproximadamente 70 ms) até as com duração de 15 segundos.

As janelas de 1 segundo, porém, apresentaram sempre os melhores resultados. Janelas menores normalmente tendiam a fornecer informação insuficiente aos módulos de processamento,

pois “fragmentavam” em demasiado as DEs, além de aumentarem substancialmente o problema de distorções nas bordas dos vetores (vide seção 5.5). Já as janelas maiores diminuía a sensibilidade dos módulos às ocorrências epileptiformes, que são de curta duração (70 a 200 ms) e exigiriam redes neurais de grandes dimensões, para atender à representação da entrada. Assim, arbitrou-se os vetores de 1 segundo  $s_{ij}(k)$ , com  $F_s = 100$  Hz e  $k=1, \dots, 100$  pontos de amostragem de registro, como os que seriam utilizados.

Esta rotina de divisão dos arquivos em épocas de 1 segundo, entrega então os vetores  $s_{ij}$ , seqüencialmente aos módulos restantes, da seguinte forma: para o segundo atual  $i \in [1, 15]$ , analisa os canais  $j = 1, \dots, 32$ , antes de passar ao segundo  $i+1$ . Quando o programa termina de analisar os 15  $i$ , pega o próximo arquivo da memória, referente aos próximos 15 segundos de registro.

#### 5.7.4 Cálculo dos Máximos e Verificação de Threshold

Por fim, o Módulo de Condicionamento pega todos os trechos de 1 segundo, de cada vetor transformado, reconstruído e normalizado, A, B e C, e calcula seus valores máximos, para tentar identificar os picos candidatos à espícula que ocorreram em cada segundo.

Isto é feito porque em um sinal de 15 segundos podem ocorrer inúmeras espículas. Já em um trecho de 1 segundo, a princípio, poucas ocorrerão (no máximo uma dezena e apenas para o caso de um complexo poliespícula-onda, com as espículas centradas na época). De qualquer maneira, a detecção de um único pico epileptiforme, na época de 1 segundo, já é suficiente para levantar a hipótese da ocorrência de espículas naquele segundo.

Assim, para um determinado trecho de 1 segundo dos sinais A, B e C, encontra-se o pico de amplitude máxima absoluta. Se este tiver valor relativo superior ao *threshold* de 7,5 desvios em relação à média, em qualquer um dos sinais, todos os 3 sinais serão enviados ao Módulo de Análise Neural. Caso contrário, se o *threshold* não foi ultrapassado em nenhum ponto da época, arbitra-se que não ocorreu nenhum evento epileptiforme e passa-se à análise da próxima época, do próximo canal.

Este procedimento possibilitou agilizar sobremaneira o processamento, pois evitou que sinais “bem-comportados”, isto é, sem presença de eventos paroxísticos, fossem analisados pelos módulos seguintes do sistema sem necessidade.




Figura 5.20: Diagrama de Blocos simplificado do Módulo de Condicionamento dos sinais.




Figura 5.21: Acima – Padrões ambíguos no EEG (segundos 5 e 13) com morfologias epilépticas devidos a ritmo alfa. Abaixo – saída da FWT, indicando que nenhum evento ultrapassou o *threshold* de 7,5 desvios. O sinal não foi, então, enviado ao Módulo de Análise Neural.




Figura 5.22: Acima – Padrões epilépticos ambíguos no EEG (segundos 6-8 e 11), mas desta vez com espícula real no segundo 11 (retângulo tracejado). Abaixo – saída da FWT, indicando que apenas o evento espícula ultrapassou o *threshold*, com quase 10 desvios além da média. A época do 11º. segundo seria enviada ao Módulo de Análise Neural.



## 5.8 Módulo de Análise Neural

A grande dificuldade encontrada na detecção automática de espículas e ondas agudas é a distinção entre estes padrões epileptogênicos de fato, e os padrões epileptiformes muito semelhantes, como algumas formas de ruídos musculares, piscadas e movimentos oculares rápidos e alguns tipos de surtos de ondas alfa. Não fossem estas manifestações, que podem gerar falsas detecções até por revisores humanos treinados, e o problema computacional de reconhecimento automático de espículas já estaria resolvido. Note-se as semelhanças morfológicas entre os padrões epileptogênicos e os epileptiformes ilustrados nas figuras que seguem (Figura 5.23, Figura 5.24, Figura 5.25 e Figura 5.26 ).




Figura 5.23: Acima – padrões epileptiformes referentes a ritmo alfa (sempre mais intenso nas regiões occipitais). Abaixo – Crise Epiléptica Eletroencefalográfica, neste caso mais intensa na região posterior direita do córtex. Notar também os eventos piscadas rápidas, de grandes amplitudes, no instante 13:35:49. Trechos recortados de telas de apresentação do SIDAPE.

Apesar de o Módulo de Transformação eliminar consideravelmente eventos que não são interessantes dos sinais, este não é capaz de fornecer por si só uma saída conclusiva, na qual seja possível decidir-se sobre a ocorrência dos eventos. Por exemplo, em vários trabalhos anteriores de projetos de sistema automatizado de reconhecimento de espículas (vide Cap. 4) houve uma forte

influência do ritmo alfa nas falsas detecções positivas. Felizmente, descobriu-se ao longo deste trabalho que a banda alfa é bastante filtrada utilizando-se a FWT Coiflet 1 e manifesta-se pouco na maioria dos sinais reconstruídos (vide Figura 5.21, por exemplo). Isto permitiu que não fosse preciso implementar-se uma RNA para reconhecimento de ritmo alfa. O mesmo não ocorre, porém, com padrões de piscadas rápidas e alguns ruídos musculares e artefatos de eletrodo. Advém daí a necessidade das RNAs: fazerem esta diferenciação que não é possível apenas com o uso da FWT. A FWT tem a função de facilitar as tarefas dos Módulos posteriores, mas não resolve o problema, absolutamente.




Figura 5.24: Acima – padrões epileptiformes referentes a movimento ocular (presentes apenas nos canais frontais), nos canais Zy1-Zy2 e Eogl-Eogr. Abaixo – Espículas “Ordinárias” (pouco evidentes/claras) espalhadas pelo hemisfério direito do córtex. Trechos recortados de telas de apresentação do SIDAPE.

Na tentativa de minimizar a influência destes padrões no desempenho do sistema pensou-se em submeter a saída dos Módulos de FWT e de Condicionamento à análise Neural, a qual faria uma seleção dos eventos realmente epileptogênicos. O problema é que treinar uma única rede neural para diferenciar entre 4 padrões diferentes (normal, espícula, ruído, piscadas) mostrou-se impraticável, em testes preliminares. Pensou-se, então, em treinar uma rede neural para o reconhecimento específico de cada um destes padrões, o que deveria teoricamente facilitar os processos de treinamento e fornecer maior confiabilidade nos resultados (diminuição das falsas detecções positivas, principalmente).






Figura 5.25: Acima – padrões epileptiformes referentes a artefatos (provavelmente artefatos de paciente e de eletrodo). O padrão à esquerda manifestou-se, inclusive, em vários canais, já o à direita é um paroxismo isolado, e portanto, mais fácil de se refutar. Abaixo – Espículas rápidas, semelhantes a ruídos musculares, principalmente no instante de registro 22:33:13. Trechos recortados de telas de apresentação do SIDAPE.




Figura 5.26: Acima – padrões epileptiformes referentes a piscadas (manifestam-se apenas nos canais frontais e possuem morfologia de “v”). Abaixo, no penúltimo segundo de registro do trecho – Ondas Agudas (ou “sharp”) epileptogênicas e com morfologia de “v”. Trechos recortados de telas de apresentação do SIDAPE.



Desta forma, até o estágio de Análise Neural, nenhuma detecção efetiva é realizada e esta é a função do grupo de RNAs, ou Módulo de Análise Neural. Na verdade, a decisão final sobre a detecção é realizada em conjunto com os resultados fornecidos pelo banco de RNAs e as regras de produção do Módulo de Regras.

### 5.8.1 Arquiteturas e Topologias das Redes

A topologia escolhida para as Redes do sistema foi a de Perceptron Multicamada (MLP), também chamada de Rede “Direta” ou *Feedforward*. O treinamento foi *supervisionado* e utilizou o algoritmo *Backpropagation*. O treinamento supervisionado foi escolhido porque os eventos a serem reconhecidos pela rede eram conhecidos<sup>20</sup>.

A dimensão de saída dos vetores transformados e condicionados nos módulos anteriores determinou também o número de neurônios das camadas de entrada das redes, ou seja, 100 unidades. Este é um tamanho razoável para entrada de uma rede neural, o qual permite que a rede receba uma quantidade razoável de informações a cada passo de treinamento ou teste; sem sobrecarregar o processamento e a memória no computador.

Optou-se por utilizar apenas um neurônio na saída de cada rede por ser um número suficiente para separar adequadamente os espaços de saída das redes. Como cada uma deveria apenas sinalizar a ocorrência de um determinado evento DE, ou não, uma saída bipolar (com valores no intervalo [-1,+1]) foi o bastante. Na verdade, mesmo uma simples saída binária unipolar já seria suficiente (ou seja, saídas com valores 0 ou 1, apenas). Porém algumas características peculiares da rede de detecção de espículas levaram à decisão pela saída bipolar contínua, tal como será visto adiante.

Já o número de neurônios *hidden* deveria ser um valor intermediário entre o número de unidades de entrada e a unidade de saída e o menor possível, sem prejudicar o desempenho das redes e de forma a também minimizar o tempo de processamento. Para isto, utilizou-se o critério recomendado pelo Prof. Jorge Muniz Barreto, da Universidade Federal de Santa Catarina:

$$N_H = \sqrt{N_E \cdot N_S} \quad (\text{Eq. 5.4})$$

onde  $N_E$  é o tamanho da camada de entrada,  $N_S$  é o tamanho da camada de saída e  $N_H$  é o tamanho da camada *hidden*, para uma rede com uma camada de entrada mais duas camadas de processamento. Assim, chegou-se à aproximação inicial de 10 neurônios *hidden*, ou ocultos. Foram implementadas e testadas também redes com 20 e redes com 12 neurônios internos.

<sup>20</sup> De modo geral, treinamentos não-supervisionados são mais apropriados para casos onde não está bem determinado o que se espera na saída da rede, para cada padrão de treinamento apresentado.

Como forma de aumentar a confiabilidade dos procedimentos de treinamento e garantir que este convergisse de forma estável para um erro mínimo global, ou mesmo um erro mínimo local abaixo do erro máximo esperado, optou-se pela utilização de um *coeficiente de treinamento adaptativo*  $\eta(t)$  no algoritmo *Backpropagation*. Isto é, o passo de aprendizagem é mantido com um valor tão alto quanto possível (para acelerar o tempo de treinamento) enquanto o treinamento se mantiver estável (com o valor de erro global diminuindo progressivamente). A Figura 5.27 ilustra a variação da taxa de aprendizagem durante o treinamento da RNA definitiva de reconhecimento de espículas.




Figura 5.27: Curvas de Treinamento para a rede definitiva RNA1 do sistema, de reconhecimento de espículas. Acima, a evolução do Erro Quadrático Global, por ciclo de treinamento. A rede foi treinada em 295 mil ciclos, aproximadamente, até atingir-se o Erro Global Máximo de 0,01. Abaixo, a variação da taxa de aprendizado, ao longo deste treinamento: quando o erro mantinha-se em decréscimo, a taxa de aprendizado era aumentada e quando o erro aumentava de um ciclo para o outro a taxa de aprendizado tinha seu valor diminuído.

Já um fator *momentum* foi utilizado para fornecer certa inércia aos treinamentos, ou seja, fazer os gradientes de pesos atuais dependentes não só da regra *backpropagation* para o valor de erro atual encontrado, mas também de alterações passadas nos valores dos pesos das conexões, em ciclos de treinamento anteriores. Isto tem como efeito diminuir a sensibilidade das redes a pequenos detalhes na superfície do erro e impedir que o treinamento fique estacionado em um mínimo local.

A inicialização dos pesos para o primeiro ciclo de aprendizagem para cada rede treinada foi realizada com valores aleatórios dentro do intervalo  $[-1 ; 1]$ . A ordem de apresentação dos padrões às redes também foi randomizada. Já os valores de ativações dos neurônios foram inicializados com valores nulos.



O número de ciclos máximo arbitrado para cada treinamento variou em função da complexidade da tarefa que deveria ser “aprendida” por cada rede (utilizou-se valores entre 80.000 e 300.000 ciclos de treinamento).

Ao todo, dezesseis diferentes redes neurais tipo MLP foram treinadas utilizando-se o algoritmo *backpropagation* e apenas as 4 que forneceram melhores resultados foram mantidas no SIDAPE. Todas seguiram quase a mesma topologia, em função do que se esperava do processamento neural. As características comuns de topologia foram:

- Número de Camadas<sup>21</sup>: 3
- Número de Neurônios de Entrada: 100 (equivalente a 1 segundo nos registros de EEG)
- Número de Neurônios da Camada de Saída: 1
- Função de Saída para os neurônios das 2 camadas: tangente hiperbólica
- Coeficiente de Treinamento inicial  $\eta(0)$ : 0,1
- Taxa de Incremento do Coeficiente de Treinamento: 1,05
- Taxa de Decremento do Coeficiente de Treinamento: 0,7
- *Momentum*: 0,97

As redes diferiram, basicamente, nas seguintes características:

- Tamanho e composição do vetor de Treinamento  $P$ ;
- Número de Neurônios da Segunda Camada: 10, 12 ou 20
- Erro Global Máximo Permitido.

De modo geral, para cada rede utilizou-se uma matriz de treinamento (treinamento em *batch*, ou “em lote”)  $P$ , de dimensões  $100 \times 3N$ , onde  $N$  é o número de sinais de 1 segundo utilizados para o treinamento desta rede. Cada sinal foi decomposto em uma reconstrução de detalhe Coiflet 1, em nível dependente da aplicação da rede. Cada vetor resultante  $P(1:100,i)$ , onde  $i$  é o vetor ou sinal atual de 100 pontos, foi então rotacionado 3 vezes, gerando ao final 3 vetores defasados entre si:  $P(1:100,i+1) = P(34:33,i)$  e  $P(1:100,i+2) = P(67:66,i)$ . Isto foi feito para eliminar o efeito de *delay* nos treinamentos, ou seja, insensibilizar as RNAs aos atrasos<sup>22</sup>. A opção

<sup>21</sup> Alguns autores não consideram o Vetor de Entrada como sendo uma Camada da Rede. Neste caso, leia-se 2 camadas para cada rede neural.

<sup>22</sup> Se não for tomado este cuidado a rede pode ser treinada, ao final, apenas para o reconhecimento de um determinado padrão localizado em um determinado ponto específico do vetor de treinamento. Por exemplo, se os vetores de treinamento apresentarem espículas posicionadas sempre na primeira terça do vetor, a rede pode tornar-se incapaz de reconhecer espículas que apareçam nas segundas e terceiras terças do mesmo.



por dividir-se o vetor em 3 (e não em 2, ou em 4, 5, etc) disse respeito ao período normal de duração do conjunto espícula-onda, que é da ordem de 300 ms, aproximadamente.

Após a rotação, os três vetores derivados foram utilizados no treinamento, após uma randomização (para que os sinais com o mesmo conteúdo, porém em ordens trocadas, fossem apresentados seqüencialmente à rede).

Na rotina de treinamento, a matriz  $P$  foi novamente randomizada (porque os sinais provenientes de um mesmo paciente estavam próximos na matriz) e normalizada, com relação ao valor máximo de amplitude absoluta encontrado em toda a matriz. O vetor alvo ("target")  $T$ , de comprimento  $3N$ , foi levantado para cada um dos sinais da seguinte forma:

SE  $P(j,i)$  "corresponde a padrão epileptiforme" ENTÃO  $T(i) = 1$ ;

SENÃO  $T(i) = 0$ ; FIM SE.

Finalmente, foi realizado o treinamento de cada rede utilizando-se os parâmetros de otimização do algoritmo *Backpropagation*<sup>23</sup> até que o Erro Global Máximo permitido fosse atingido, ou que o número de ciclos superasse o máximo assumido.

Os treinamentos foram implementados no software MATLAB 5.1®, rodando em um microcomputador IBM-PC, com processador Pentium de velocidade de 500 MHz e sistema operacional Windows98.

As particularidades de cada RNA serão detalhadas na seqüência e a Figura 5.28 ilustra a arquitetura das redes definitivas.




Figura 5.28: Topologia das redes neurais do SIDAPE. Rede direta, completamente conectada entre camadas e treinada com algoritmo supervisionado *Backpropagation*.

<sup>23</sup> No MATLAB 5.1, este procedimento é realizado pela função *trainbpx(.)*.

### 5.8.2 RNA1 - Rede para Reconhecimento de Espículas:

Uma quantidade grande de sinais de 1 segundo, contendo espículas e formas de onda normais, transformados e reconstruídos a partir da Coiflet 1, detalhe 2, foi utilizada em conjuntos de treinamento para a rede que reconheceria os *spikes*. Ao total foram aproximadamente 200 sinais diferentes, combinados de várias formas, até que se chegasse a um conjunto final, o qual forneceu os melhores resultados de desempenho para a RNA1.

A primeira rede treinada e testada, por exemplo, utilizou apenas 5 vetores com espículas “Perfeitas” e 5 espículas “Comuns” e 19 vetores normais, dentre estes 5 com ocorrência de uma quantidade moderada de ruído e piscadas. Ou seja, um total de 29 arquivos de treinamento. Já o conjunto de teste utilizou um total de 15 arquivos: 4 de espículas “Perfeitas”, 4 de espículas “Comuns”, 5 absolutamente “Normais” e 2 arquivos com algum ruído. Surpreendentemente, a rede acertou 93% das classificações (apenas um dos arquivos com espícula “Comum” apresentou saída igual a 0,63, ou seja, abaixo do *threshold* arbitrado). Estes valores estão todos listados nas Tabela 5.2 e Tabela 5.3. Pode-se notar que se tentou variar ao máximo os pacientes e canais utilizados no treinamento de forma a fornecer um amplo espaço de dados à rede. Quando se tentou, porém, extrapolar os testes com outros arquivos, a rede não foi capaz de generalizar. Atribuiu-se este problema à variabilidade de padrões em EEGs.

Tabela 5.2: Conjunto de Treinamento da primeira rede RNA1 implementada. Foram utilizadas 29 épocas de 1 segundo de duração. O nome do paciente que forneceu a época e a janela de 15 segundos/32 canais onde esta foi selecionada são dados pela coluna *Nome do Arquivo*. Dentre os 32 ou 24 canais da janela de 15 segundos, retirou-se a época do canal dado pela coluna *Número do Canal*, segundo a montagem zigomática-temporal e do “segundo” dado pelo intervalo de amostragem [*Ponto inicial na janela*, *Ponto inicial na janela*+99]. A coluna *Tipo de Sinal* fornece o tipo de evento constante na época. A coluna *Valor Target* indica se este evento é epileptogênico (próximo ou igual a 1), ou não (próximo ou igual a 0).

No. do Arquivo	Nome do Arquivo	No. do Canal	Ponto inicial na janela	Tipo de Sinal	Valor Target
[1]	Lap_3510	31	800	Espícula-Onda Perfeita	1
[2]	Sr_945	8	1000	Espícula-Onda Perfeita	1
[3]	Zog_1815	6	1200	Espícula-Onda Perfeita	1
[4]	Kur_330	4	1200	Espícula-Onda Perfeita	1
[5]	Vad1_1260	14	1000	Espícula-Onda Perfeita	1
[6]	Wam_30	29	200	Espícula-Onda Comum	1
[7]	Vad2_2250	21	1000	Espícula-Onda Comum	1
[8]	Jok_60	13	500	Espícula-Onda Comum	1
[9]	Sr2_15	11	600	Espícula-Onda Comum	1
[10]	Vad1_1530	1	1400	Espícula-Onda Comum	1
[11]	Jok_30	1	800	Normal com Ruído	0
[12]	Kur_15	28	600	Absol. Normal	0



[13]	Kur_15	27	800	Absol. Normal	0
[14]	Lap_15	23	1000	Absol. Normal	0
[15]	Lap_75	30	1300	Absol. Normal	0
[16]	Sr_15	21	1000	Normal com Piscada	0
[17]	Sr_60	2	200	Normal com Ruído	0
[18]	Sr_60	31	100	Absol. Normal	0
[19]	Sr_135	21	1100	Absol. Normal	0
[20]	Sr2_15	16	100	Absol. Normal	0
[21]	Vad1_15	6	1200	Normal com Ruído	0
[22]	Vad1_60	20	1200	Absol. Normal	0
[23]	Vad2_15	4	300	Absol. Normal	0
[24]	Vad2_15	29	700	Absol. Normal	0
[25]	Wam_15	2	300	Absol. Normal	0
[26]	Wam_15	3	100	Absol. Normal	0
[27]	Wam_15	5	100	Normal com Ruído	0
[28]	Zog_15	32	100	Absol. Normal	0
[29]	Zog_15	10	400	Absol. Normal	0

Tabela 5.3: Conjunto de Teste da primeira rede RNA1 implementada. Apenas o arquivo [7] não forneceu uma saída próxima do valor 1 esperado.

No. do Arquivo	Nome do Arquivo	No. do Canal	Ponto inicial na janela	Tipo de Sinal	Valor Saída
[1]	Wam_720	8	1000	Espícula-Onda Perfeita	0.98
[2]	Vad2_2955	4	900	Espícula-Onda Perfeita	0.72
[3]	Jok_585	27	800	Espícula-Onda Perfeita	-0.96
[4]	Sr2_1080	21	1100	Espícula-Onda Perfeita	-0.95
[5]	Lap_3120	29	700	Espícula-Onda Comum	0.95
[6]	Sr_15	4	300	Espícula-Onda Comum	0.84
[7]	Zog_225	4	1400	Espícula-Onda Comum	0.63
[8]	Kur_3060	1	1200	Espícula-Onda Comum	-0.88
[9]	Jok_30	1	800	Normal com Ruído	-0.00
[10]	Lap_240	24	300	Absol. Normal	0.00
[11]	Sr2_1440	3	1200	Normal com Delta	-0.00
[12]	Sr_60	2	200	Normal com Ruído	0.00
[13]	Kur_120	8	600	Absol. Normal	0.00
[14]	Zog_120	14	400	Absol. Normal	-0.00
[15]	Vad1_120	19	400	Absol. Normal	0.00



Muitos dos arquivos utilizados, apesar de possuírem espículas óbvias, perfeitas, faziam com que as redes treinadas fossem incapazes de generalizar, ou que se tornassem incapazes de diferenciar entre sinais com espículas e sinais normais. Isto aconteceu principalmente devido à morfologia particular destes arquivos ou por não serem capazes de gerar coeficientes adequados após a transformação FWT, como ocorreu com o sinal [7] do primeiro conjunto de teste. Este apresentou um pico correspondente à espícula com apenas 4 desvios-padrão em relação à amplitude média para o trecho. Por esta razão, todos estes arquivos foram rejeitados e apenas sinais que não geraram ambigüidades foram utilizados.

A partir dos testes realizados com outros arquivos, foi-se aumentando gradativamente o conjunto de treinamento da seguinte forma: caso o arquivo com espícula fornecesse a saída em módulo próxima a 1 seria mantido no conjunto. Caso contrário, seria retirado para evitar que a rede convergisse para mínimos locais ou que fosse incapaz de convergir, como aconteceu algumas vezes. Também, caso o arquivo normal testado gerasse um valor alto na saída, em módulo, este era acrescentado ao conjunto de treinamento com valor *target* forçado de '0' e nova rede era treinada, com o objetivo de aumentar a capacidade de generalização desta.




Figura 5.29: Exemplos de épocas de 1 segundo utilizados no treinamento da primeira rede RNA1. No alto: à esquerda, sinal *vad1\_1260* [5], com espícula de período positivo entre os pontos 60 e 80. No alto: à direita, sinal *lap\_15* [14], absolutamente normal. Abaixo, ao centro: sinal *wam\_15* [25], normal com onda lenta.

Uma característica muito interessante emergiu já nos primeiros treinamentos realizados: as redes que utilizavam funções de saída unipolares (a logística, ou *logsig()* no MATLAB) não foram capazes de detectar as espículas de polaridades positivas, apenas as negativas! Ou seja, normalmente quando o padrão apresentado consistia de uma espícula com pico positivo (como no

senal [1] do conjunto de teste, que apresenta espícula com pico positivo e que forneceu valor absoluto de 0,98 na saída), a rede fornecia valores de ativação do neurônio de saída próximos a 1. Porém, quando a projeção da espícula era negativa, o valor de saída ficava próximo de 0, o que deveria ser uma saída para padrão normal de entrada. Por esta razão, utilizou-se a função de ativação bipolar (tangente hiperbólica, ou *tansig()* no MATLAB) a qual forneceu as saídas como se desejava: com módulos próximos a 1, quando havia um evento espicular (como no caso do sinal [3] do conjunto de teste, que apresenta duas espículas com projeções positivas e forneceu saída bipolar igual a  $-0,96$ ) e com módulos próximos a 0, quando o padrão era normal.




Figura 5.30: Exemplos de trechos de 1 s utilizados no teste da primeira rede RNA1 e corretamente classificados. No alto: à esquerda, sinal *wam\_720* [1], com espícula de projeção positiva entre os pontos 40 e 60. No alto: à direita, sinal *jok\_585* [3], com ocorrência de duas espículas-onda consecutivas. Abaixo, à esquerda: sinal *sr2\_1080* [4], com complexo biespícula-onda ao centro. Abaixo, à direita: sinal *lap\_240* [10], normal com pequena atividade alfa no início.

A saída da rede RNA1, então, é considerada em módulo, apesar de bipolar. E o *threshold* escolhido para a detecção positiva é de 0,7. Isto é, quando o valor de saída para o neurônio de saída da rede é superior a 0,7, o programa considera que houve uma detecção e a variável *detectou\_spike* recebe valor 1, para aquele canal, durante aquele segundo de análise. Quando é inferior, a variável *detectou\_spike* é zerada. Este valor de 0,7 foi assumido após muitas observações e como um ponto ótimo entre sensibilidade e especificidade da rede.

O tempo de processamento nos treinamentos variou de 30 minutos a 12 horas, dependendo do teor e do tamanho da matriz de treinamento.




Figura 5.31: Padrão classificado erroneamente pela rede. Apesar de ser uma espícula óbvia, o vetor reconstruído a partir dos detalhes 2 Coiflet 1 forneceu um pico referente à espícula com amplitude muito baixa, além da média. Mesmo o vetor reconstruído a partir dos detalhes 3 apenas forneceu um pico de 6 desvios em relação à média.

O algoritmo *Backpropagation* otimizado de “Levenberg-Marquardt”, de grande velocidade de treinamento foi testado, mas não forneceu bons resultados.

Finalmente, o conjunto definitivo selecionado para treinamento da RNA1 consistiu de 93 sinais: 41 com presença de espículas claras, perfeitas e que não geraram ambigüidades na rede e 52 arquivos, na sua grande maioria absolutamente normais, pois o treinamento com piscadas e ruídos foi deixado ao encargo das demais redes.

Assim, a rede RNA1 foi treinada com  $3 \times 93 = 279$  vetores de treinamento, em aproximadamente 150.000 ciclos (8 horas) seus valores de polarização e pesos para a primeira e a segunda camada foram guardados em memória e a rede foi testada já diretamente nos registros completos, apresentados seqüencialmente, tal como será visto no Cap. 6.

O número de neurônios *hidden* escolhido foi 12, por ter gerado uma rede mais capaz de generalizar que as redes com 10 ou 20 neurônios intermediários.



### 5.8.3 RNA2 - Rede para Reconhecimento de Ondas Agudas:

Assim como no treinamento da rede para reconhecimento específico de espículas, o treinamento da rede RNA2 foi uma tarefa difícil e longa. Mas era imprescindível que isto fosse feito, principalmente porque vários eventos epileptogênicos encontrados na base de dados simplesmente não geraram coeficientes de detalhe 2 significativos mas geraram coeficientes de altos valores no sinal reconstruído a partir do detalhe 3, Coiflet 1.

Isto provavelmente ocorre devido ao conteúdo espectral da banda de escala 3 da *wavelet* Coiflet 1, o qual é de menores frequências. Ou seja, todas as espículas mais lentas, chamadas pelos revisores de “ondas agudas”, ou *sharp* e tão indicativas de Epilepsia quanto as primeiras, não apareciam no sinal reconstruído a partir do detalhe 2, mas poderiam aparecer na componente de detalhe 3, a qual envolve eventos mais lentos, compostos de frequências menores.

Assim, para solucionar o problema de treinar redes sensíveis a espículas *E* a ondas agudas pensou-se em várias alternativas: algumas redes foram treinadas com somatórios dos sinais reconstruídos a partir das duas componentes, algumas com médias entre estes dois detalhes, mas a abordagem mais bem sucedida foi treinar redes em separado para o reconhecimento dos dois eventos: uma somente para espículas rápidas, a RNA1, e uma para espículas mais lentas, a RNA2, a qual utiliza o sinal obtido do detalhe 3. Espera-se com isto que a maioria dos paroxismos epileptogênicos sejam captados, ou pelo vetor de detalhe 2 ou pelo de detalhe 3.

Os valores de saída das duas redes são comparados pelo sistema e a saída que obtém maior valor em módulo é a considerada.

O conjunto de arquivos para treinamento da rede RNA2 definitivo consistiu de 36 arquivos com ondas agudas e 52 arquivos absolutamente normais, totalizando 88 arquivos de treinamento e  $3 \times 88 = 264$  vetores de treinamento para a matriz *P*. A Figura 5.32 ilustra exemplos dos arquivos utilizados.

Esta rede também utilizou 12 neurônios *hidden* e *threshold* de 0,7 para a detecção positiva/negativa. O treinamento foi concluído em aproximadamente 200.000 ciclos, durante 10 horas.

Seus valores de polarização e pesos para a primeira e a segunda camada foram também armazenados em memória para testes posteriores já nos registros completos, com 32 canais e janelas de 15 segundos apresentadas seqüencialmente, tal como será visto no Cap. 6.




Figura 5.32: Exemplos de arquivos utilizados para o treinamento da rede RNA2. As ondas agudas estão marcadas com elipses e os vetores abaixo mostram os sinais reconstruídos a partir dos vetores de coeficientes detalhe 3 da FWT Coiflet 1. Todos os arquivos resultaram em picos de amplitude discrepantes em relação à média para o detalhe 3 e em picos de amplitudes consideravelmente menores para o detalhe 2.

#### 5.8.4 RNA3 - Rede para Reconhecimento de Ruídos e Artefatos Musculares:

O tipo de ruído cuja influência se desejava eliminar ou diminuir do sistema era justamente aquele composto de frequências menores (da ordem de 10 a 15 Hz), as quais coincidem com frequências dominantes em espículas e ondas agudas. Assim, o uso dos sinais obtidos a partir dos detalhes 2 e 3 da FWT implicaria em treinar redes capazes de diferenciar ruídos de espículas, o que é difícil, em alguns casos, até para revisores humanos, realizando análises visuais.

No entanto, este tipo de ruído aparece normalmente mesclado a uma atividade de frequência mais alta, grande energia e curta duração. Ou seja, a detecção do ruído pode ser feita de forma indireta: utilizando-se a componente de detalhe 1 na reconstrução dos sinais  $C$ , este tipo de ruído de grande energia é facilmente captado e assim pode-se treinar uma rede que diferencie entre este tipo de evento e a atividade normal, sem a preocupação de fazer a diferenciação entre o ruído mais lento e as espículas, que é uma tarefa mais complexa.

Foram treinadas 4 redes especificamente para o reconhecimento de ruídos nos sinais de EEG e manteve-se apenas a que forneceu melhores resultados (curva de treinamento na Figura 5.33) por ter sido treinada com o conjunto de treinamento mais adequado. A rede definitiva para reconhecimento de ruídos RNA3 foi treinada com 25 arquivos de ruído e 25 arquivos normais, totalizando 50 arquivos de treinamento e 150 vetores na matriz  $P$ . A rede convergiu para o Erro Máximo Global de 0,01 em aproximadamente 100.000 ciclos de treinamento (6 horas, mais ou menos).




Figura 5.33: Curvas de treinamento da rede utilizada para reconhecimento de ruídos e artefatos no SIDAPE.

A Figura 5.34 ilustra exemplos dos arquivos utilizados.




Figura 5.34: Dois exemplos de sinais utilizados no treinamento da rede de reconhecimento de ruídos RNA3.

À esquerda – no alto vê-se o sinal de EEG com ruído muscular e seu correspondente vetor reconstruído a partir do detalhe 3, ao centro. Notar que o pico do sinal reconstruído ultrapassou o limiar tal como o faria uma espícula. Para evitar o problema de uma falsa detecção positiva a rede RNA3 foi treinada com o sinal na posição inferior, ou seja, o vetor reconstruído a partir dos coeficientes de detalhe 1, os quais guardam a informação da ocorrência de altas frequências no sinal original e além da banda de frequências das espículas e ondas agudas. À direita – a mesma situação do sinal anterior, só que desta vez foi o vetor obtido a partir do detalhe 2 que “detectou” a falsa espícula. À direita e abaixo se vê o vetor utilizado para treinamento da RNA3.



Os demais parâmetros seguiram o que foi utilizado nas outras redes e, ao final do treinamento, as matrizes de polarização e pesos foram armazenadas em memória para utilização nos procedimentos de teste.

#### **5.8.5 RNA4 - Rede para Reconhecimento de Piscadas:**

Por fim, foi necessário treinar-se apenas duas redes para o reconhecimento de piscadas, até atingir-se resultados satisfatórios dado que a morfologia da piscada é uma das mais características, simples e de menor variabilidade. No entanto, o movimento ocular tipo *piscada*, ou *blink*, é um dos eventos mais confundidos com espículas, em sistemas automáticos.

A diferenciação entre uma espícula e uma piscada pode vir a ser uma tarefa complexa, já que ambas têm como características as altas amplitudes e o formato espicular. Se o movimento ocular que gerou a piscada foi rápido, o registro eletroencefalográfico referente à mesma aproxima-se morfologicamente do registro referente a uma atividade epilética, podendo confundir um sistema automático e até mesmo um observador inexperiente.

Porém as piscadas são facilmente identificáveis a olho nu, pois apresentam morfologia de ‘u’ (ou de ‘v’, as mais agudas), altas amplitudes e ocorrem simultaneamente apenas nos canais referentes a eletrodos localizados nas regiões facial e frontal (mais especificamente, Zy1-Zy2, Eogl-Eogr, Fp1-F7, F7-T3, Fp2-F8, F8-T4, Fp1-F3, F3-C3, Fp2-F4, F4-C4, Fp1-F9, F9-T9, Fp2-F10 e F10-T10). Por esta razão, a rede RNA4 só analisa sinais provenientes dos canais faciais e frontais citados e o SIDAPE desconsidera detecções de espículas que tenham supostamente ocorrido apenas nestes canais. As piscadas têm durações entre 200 e 500 ms (movimentos oculares mais lentos que isto são anulados na transformação FWT até a escala 3 e por isto não foram considerados), em média e sempre possuem polaridade positiva.

Foram utilizados 10 arquivos de sinais reconstruídos a partir do detalhe 3 contendo piscadas “perfeitas”, 10 arquivos com piscadas mais “rápidas” e 20 arquivos normais, no treinamento da RNA4.

A convergência da rede deu-se em 200.000 ciclos de treinamento (com duração aproximada de 10 horas), até atingir o Erro Global Máximo de 0,01.

A Figura 5.36 ilustra exemplos dos arquivos utilizados.

Os demais parâmetros seguiram o que foi utilizado nas outras redes e, ao final do treinamento, as matrizes de polarização e pesos foram armazenadas em memória para utilização nos procedimentos de teste.




Figura 5.35: Curvas de treinamento da rede destinada ao reconhecimento de piscadas e movimentos oculares no SIDAPE.




Figura 5.36: Dois exemplos de sinais utilizados no treinamento da rede RNA4 de reconhecimento de piscadas e seus vetores reconstruídos a partir do detalhe 3 abaixo.

A Tabela 5.4 resume os tamanhos e conteúdo dos conjuntos de treinamento para cada uma das redes.

Tabela 5.4: Dados sobre os conteúdos e os tamanhos dos Conjuntos de Treinamento das Redes Neurais Artificiais do SIDAPE.

Nome da Rede	CONJUNTO DE TREINAMENTO			Tamanho Total Conjunto de Treinamento
	Tipo Evento a discriminar	No. Épocas com Evento	No. Épocas Normais (sem o Evento)	
RNA1	Espículas	41	52	93
RNA2	Ondas Agudas	36	52	88
RNA3	Ruído	25	25	50
RNA4	Piscadas	20	20	40

## 5.9 Módulo de Análise Simbólica por Regras de Produção

Este conjunto de rotinas do SIDAPE é responsável pela verificação “inteligente” do que foi realizado nos módulos anteriores. Realiza o cruzamento entre as saídas das RNAs, as ultrapassagens de *thresholds*, a localização da ocorrência de eventos, em relação aos canais e faz julgamento sobre a procedência destes fatos, etc.

Outras regras poderiam também ter sido implementadas. Porém acredita-se que as regras mais importantes já tenham sido incorporadas ao SIDAPE e deixa-se as demais como sugestões a trabalhos futuros (vide Capítulo 9 ).

Estas regras são simples e foram construídas com o objetivo de solucionar, primariamente, algumas falhas de detecção e classificação dos módulos anteriores. Algumas destas já foram citadas nas seções anteriores para maior esclarecimento. As seções abaixo as descrevem de forma simplificada e não-codificada para facilitar o entendimento.

Os parâmetros e valores de crença foram arbitrados segundo observações empíricas da autora, ao longo do trabalho, mas devem ser tornados ajustáveis, em trabalhos futuros, para maior flexibilização e eficiência do sistema.

### 5.9.1 Regras para Espículas

a) Regras para captar tanto evento ocorrido na rede RNA1 quanto na rede RNA2, onde houver sido mais intenso e guardar qual detalhe forneceu o máximo:

$$ocorreu\_spike(j,k) = \max(Saída\_RNA1(j,k), Saída\_RNA2(j,k));$$

$$SE Saída\_RNA1(j,k) > Saída\_RNA2(j,k)$$



$flag\_nível\_det = 2;$

SENÃO

$flag\_nível\_det = 3;$

FIM SE.

onde  $j$  é o canal atual e  $k$  é o segundo sendo analisado.

b) Regras para verificar se houve “campo”, ou “reversão de Fase” e aumentar o valor das saídas correspondentes de 10% (valor de crença arbitrado), caso positivo e diminuir em 10% (valor de crença arbitrado) a influência de um evento que esteja isolado em uma região do córtex:

SE ( $ocorreu\_spike(j,k) > 0,50$ ) E ( $ocorreu\_spike(j-1,k) < 0,50$ ) ENTÃO

$ocorreu\_spike(j,k) = ocorreu\_spike(j,k) * 1,1;$

$ocorreu\_spike(j-1,k) = ocorreu\_spike(j-1,k) * 1,1;$

FIM SE.

SE ( $ocorreu\_spike(j,k) < 0,50$ ) E ( $ocorreu\_spike(j-1,k) > 0,50$ ) ENTÃO

$ocorreu\_spike(j,k) = ocorreu\_spike(j,k) * 1,1;$

$ocorreu\_spike(j+1,k) = ocorreu\_spike(j-1,k) * 1,1;$

FIM SE.

SE ( $abs(ocorreu\_spike(j,k)) > 0,70$ ) E ( $abs(ocorreu\_spike(j-1,k)) < 0,50$ )

E ( $abs(ocorreu\_spike(j+1,k)) < 0,50$ ) ENTÃO

$ocorreu\_spike(j,k) = ocorreu\_spike(j,k) * 0,9;$

FIM SE.

c) Regra para verificar se a maior saída entre as duas redes de detecção de espículas teve valor absoluto próximo de 1 (o que indica detecção positiva):

SE  $abs(ocorreu\_spike(j,k)) > 0,70$  ENTÃO

$ocorreu\_spike(j,k) = ocorreu\_spike(j,k);$

SENÃO

$ocorreu\_spike(j,k) = 0;$

FIM SE.

### 5.9.2 Regra para Ruído

Regra para verificar se ocorreu um ruído muscular exagerado ou outros artefatos de grandes intensidades (amplitudes excessivamente altas em módulo - acima de  $220 \mu V$  ou abaixo de  $-220 \mu V$  e, portanto, acima dos níveis devidos à atividade elétrica cortical – vide Figura 5.37):

$SE \max(abs(canal(j,k))) \geq 220 \text{ ENTÃO}$

$j = j+1;$

$FIM SE.$

Ou seja, em um trecho onde ocorram amplitudes exageradas, o sinal  $canal(j,k)$  não chegará a ser analisado pelos módulos do SIDAPE e o programa passa ao próximo  $canal(j+1)$ , ou próximo segundo  $(k+1)$ . É interessante pontuar que este procedimento é seguido intuitivamente pelos eletroencefalografistas e revisores: estes simplesmente desconsideram trechos com amplitudes muito elevadas e excesso de ruído.




Figura 5.37: Ruídos musculares presentes no EEG (canais frontais-temporais esquerdos, principalmente, mas também nos canais T10-P10 e P10-O2, a partir do 11º. segundo do registro) que invalidam a análise de espículas (apesar de aparentemente existirem espículas no 2º. segundo do registro) e que possuem amplitudes muito elevadas, acima da faixa típica para sinais eletroencefalográficos.



### 5.9.3 Regras para Piscadas (Blinks)

a) Regra para verificar a ocorrência de um evento piscada e só aceitar as de polaridade positiva (vide Figura 5.38). A variável  $j$  assume apenas valores de índices dos 14 canais faciais frontais e  $n\_ocorr\_piscadas$  é uma variável que guarda o número de possíveis piscadas ocorrendo naquele segundo, nos canais faciais frontais:

$ponto\_max\_absoluto = indice(max(abs(canal(j,k)))$ ;

SE  $(abs(ocorreu\_piscada(j,k) > 0.70) \text{ E } (canal(j,ponto\_max\_absoluto) < 0) \text{ ENTÃO}$

$n\_ocorr\_piscadas = n\_ocorr\_piscadas + 1$ ;

$ocorreu\_piscada(j,k) = ocorreu\_piscada(j,k)$ ;

SENÃO

$ocorreu\_piscada(j,k) = 0$ ;

FIM SE.




Figura 5.38: Sinal de EEG com presença de eventos piscadas mais intensos nos canais Eogl-Eogr, Fp1-F7, Fp2-F8, Fp1-F3, Fp2-F4, Fp1-F9 e Fp2-F10, ao centro da tela, no instante 13:30:05.

b) Regra para só aceitar evento piscada caso este tenha ocorrido em, pelo menos, 4 canais faciais frontais:

SE  $n\_ocorr\_piscadas < 4 \text{ ENTÃO}$



*PARA j DE 1 A 14 FAÇA*

*ocorreu\_piscada(j,k) = 0;*

*FIM PARA.*

*FIM SE.*

#### 5.9.4 Regras Cruzadas

a) Regra para associar saídas das RNA1/RNA2 à saída da RNA3 e diminuir a influência de possíveis ocorrências de espículas de 20% (valor arbitrado), onde houver ruído muscular:

*SE (abs(ocorreu\_spike(j,k)) > 0) E (abs(ocorreu\_ruído(j,k) > 0,70))*

*ENTÃO*

*ocorreu\_spike(j,k) = ocorreu\_spike(j,k)\*0,8;*

*FIM SE.*

b) Regra para associar saídas das RNA1/RNA2 à saída da RNA4 e refutar possíveis confusões entre espículas e piscadas (*Canais\_Oculares* é o vetor que guarda os índices dos canais frontais faciais, isto é, {4,8,9,10,13,14,17,18,21,22,25,26,29,30}):

*flag\_ocorreu\_fora = 0;*

*PARA j DE 1 A 32 FAÇA*

*SE j não pertence a Canais\_Oculares*

*SE abs(ocorreu\_spike(j,k)) > 0,50 ENTÃO*

*flag\_ocorreu\_fora = 1;*

*FIM SE.*

*FIM SE.*

*FIM PARA.*

*SE (flag\_nivel\_det = 3) E (abs(ocorreu\_spike(j,k)) > 0) E*

*(flag\_ocorreu\_fora = 0) E (saída\_abs(ocorreu\_piscada(j,k) > 0,70))*

*ENTÃO*

*ocorreu\_spike(j,k) = 0;*

*FIM SE.*

A regra acima tem como objetivo tentar diminuir os falsos-positivos na detecção, referentes à localização de piscadas e não espículas e para isto identifica os canais onde ocorreram eventos epileptiformes durante um determinado segundo. Caso estes eventos tenham ocorrido apenas nos canais onde ocorrem as piscadas e em nenhum outro canal que não os faciais/frontais, caso o detalhe que gerou a detecção da suposta espícula tenha sido o 3 (mais sensível a piscadas que o 2) e caso a rede RNA4 tenha detectado piscadas naquele segundo, a regra desconsidera a detecção naquele segundo.

Esta regra minimiza o problema de o sistema refutar espículas em pacientes que apresentem focos epiléticos bem localizados apenas na região frontal, pois leva em conta os vários fatores e ainda possibilita que o sistema seja capaz de detectar estes focos.

### 5.9.5 Regra Final

a) Regra para gerar uma saída compacta (matriz esparsa a ser armazenada em memória, para posterior utilização nas rotinas gráficas de apresentação). Esta regra utiliza o valor da variável *ocorreu\_spike* atualizada, após o processamento nas regras anteriores, o qual é transformado em binário:

*SE*  $abs(ocorreu\_spike(j,k)) > 0,70$  *ENTÃO*

$ocorreu\_spike(j,k) = 1;$

*SENÃO*

$ocorreu\_spike(j,k) = 0;$  *FIM SE.*

O sistema SIDAPE utiliza estas regras, mas trabalhos futuros devem atuar no sentido de implementar uma base de regras talvez mais completa e utilizando raciocínio *Fuzzy*. Esta base poderá também utilizar valores obtidos a partir de testes de desempenho, dos Modelos de Gotman e da experiências de revisores.

## 5.10 Rotinas de Apresentação Gráfica

Foram implementadas rotinas para facilitar a análise dos dados de EEG, através de visualização gráfica em computador.

Estas rotinas recuperam dados da Base de Sinais, dos arquivos de Detecção e dos módulos do SIDAPE para apresentar os sinais puros ou processados.

Todas as figuras contendo sinais de EEG deste capítulo foram obtidas através de cópias das telas destas rotinas.

Em especial, a figura abaixo (reduzida para caber neste documento, mas de dimensões 800x600 pixels) ilustra uma tela de saída do SIDAPE, com as espículas detectadas ao centro.




Figura 5.39: Exemplo de tela do SIDAPE de apresentação gráfica dos sinais e dos resultados de detecção de espículas (marcadas com um fundo mais escuro), em até 32 canais, na tela do computador.



## 6. TESTES E RESULTADOS

Neste capítulo serão descritos os procedimentos de teste individuais realizados com os blocos principais do sistema SIDAPE, os testes com o sistema integrado e os resultados obtidos, em termos de precisão, sensibilidade, especificidade, valores preditivo positivo e preditivo negativo.

### 6.1 Testes com o Módulo de Transformação

Para testar-se individualmente o módulo de transformação, este foi isolado dos demais blocos do SIDAPE, ou seja, do banco de RNAs, base de regras, etc. Apenas foram mantidos os procedimentos de condicionamento dos sinais e tratamento das bordas por fazerem parte do raciocínio empregado no processamento dos sinais de EEG, via FWT.

Para garantir confiabilidade nos testes, um conjunto de 27 canais diferentes entre si (3 vetores com durações de 15 segundos, de cada arquivo de paciente) foi selecionado de forma aleatória<sup>24</sup> e submetido às rotinas de condicionamento e de Transformação *Wavelet* do SIDAPE.

O critério estabelecido foi o seguinte: a cada vez que um determinado evento gerasse um pico com amplitude além do *threshold* de desvios acima da média, este era armazenado para posterior comparação com as detecções provenientes de análise visual. Ou seja, sempre que o módulo apontasse um evento “candidato a epileptiforme”, a detecção seria marcada como positiva. E nos demais segundos, onde não houvesse transposição do *threshold*, a detecção por parte do módulo seria marcada como negativa.

Para cada um destes 27 vetores de canal analisou-se também o valor do *threshold* variando como 7,0 e como 7,5 desvios padrão acima da média.

Assim, obteve-se ao final,  $27 \text{ (vetores de canal aleatórios)} \times 15 \text{ (segundos/vetor)} \times 2 \text{ (valores de threshold)} = 810$  saídas *booleanas* (marcação positiva ou negativa de detecção de evento epileptiforme) para o módulo. Estes resultados estão resumidos na tabela abaixo.

Os testes mostraram que a eficiência individual do módulo de Transformação não seria suficiente para um sistema relativamente preciso de detecção de espículas pois ocorreram 9 falsos-

<sup>24</sup> Os arquivos foram sorteados utilizando-se uma simples rotina computacional o qual gerava um número randômico para o paciente (entre 1 e 9), outro para o instante de tempo em segundos inicial (entre 15 e 7200, mas dependendo da disponibilidade de registros de cada paciente) e um último para o canal (1 a 32 ou 1 a 24 para o paciente 5). A rotina utilizou reposição, mas cada paciente só podia ser sorteado 3 vezes, para completar 27 arquivos de canal.



positivos, para o valor de *threshold* igual a 7,0. Estas nove detecções errôneas deveram-se à presença de ruídos, piscadas e, em menor escala à presença de ritmo alfa. No entanto, as taxas de acerto podem ser consideradas relativamente altas, para ambos os *thresholds* (em torno de 96%). Os testes demonstraram também que o *threshold* de 7,0 desvios além da média é o mais adequado para garantir sensibilidade E especificidade no sistema. Ou seja, apesar da pequena distância entre um *threshold* de 7,0 para um de 7,5 desvios, esta já foi suficiente para variar o valor da sensibilidade de 65% para 55%, enquanto a especificidade do módulo permaneceu aproximadamente igual a 98%.

Tabela 6.1: Resultados dos Testes com o Módulo de Transformação para os valores de *threshold* de 7,0 e 7,5 desvios-padrão além das amplitudes médias calculadas para os registros. O *threshold* de 7,5 apresentou especificidade ligeiramente maior, mas sensibilidade consideravelmente menor que o *threshold* de 7,0. A taxa de acerto média foi de aproximadamente 96%. As colunas referem-se aos acertos e erros do Módulo, em relação às detecções, da seguinte forma: VP- verdadeiro positivo; FP- falso positivo; VN- verdadeiro negativo; FN- falso negativo.

Arquivos Teste				Threshold = 7,0					Threshold= 7,5				
# Arq.	Pac.	Arquivo	Canal	VP	FP	VN	FN	Taxa Acerto	VP	FP	VN	FN	Taxa Acerto
1	9	1260	20	0	0	15	0	100,0	0	0	15	0	100,0
2	9	4125	15	0	0	15	0	100,0	0	0	15	0	100,0
3	8	1605	20	1	1	13	0	93,3	1	1	13	0	93,3
4	1	1920	27	0	1	14	0	93,3	0	1	14	0	93,3
5	2	1095	7	0	0	15	0	100,0	0	0	15	0	100,0
6	3	720	1	0	0	15	0	100,0	0	0	15	0	100,0
7	5	3360	12	1	0	13	1	93,3	1	0	13	1	93,3
8	8	2115	7	1	1	13	0	93,3	1	1	13	0	93,3
9	8	75	22	2	0	12	1	93,3	2	0	12	1	93,3
10	3	690	7	0	1	14	0	93,3	0	1	14	0	93,3
11	3	1965	5	0	0	15	0	100,0	0	0	15	0	100,0
12	4	6195	28	0	0	15	0	100,0	0	0	15	0	100,0
13	5	3240	20	0	0	15	0	100,0	0	0	15	0	100,0
14	4	3855	24	3	0	12	0	100,0	2	0	12	1	93,3
15	5	1605	17	0	0	14	1	93,3	0	0	14	1	93,3
16	2	5295	9	2	1	12	0	93,3	1	1	12	1	86,7
17	9	1080	10	0	0	15	0	100,0	0	0	15	0	100,0
18	6	1530	17	0	2	13	0	86,7	0	1	14	0	93,3
19	4	1635	19	2	0	9	4	73,3	2	0	9	4	73,3
20	7	5250	32	0	1	14	0	93,3	0	1	14	0	93,3
21	7	1455	15	0	0	15	0	100,0	0	0	15	0	100,0
22	7	1155	27	0	0	15	0	100,0	0	0	15	0	100,0
23	2	1125	20	0	0	15	0	100,0	0	0	15	0	100,0
24	1	1695	1	0	0	15	0	100,0	0	0	15	0	100,0
25	6	60	1	0	0	15	0	100,0	0	0	15	0	100,0
26	6	210	12	0	0	15	0	100,0	0	0	15	0	100,0
27	1	435	21	1	1	13	0	93,3	1	1	13	0	93,3
$\Sigma$ : 13				9	376	7		96,0	11	8	377	9	95,8
Sensibilidade:								65,0	Sensibilidade:				55,0
Especificidade								97,7	Especificidade:				97,9



## 6.2 Testes com o Módulo de Análise Neural

O procedimento de testes do módulo de Análise Neural consistiu no isolamento do mesmo, em relação ao módulo de Análise Simbólica e aos detectores de *threshold*, e no teste individual de cada uma das redes, com relação à sua capacidade de detecção de eventos epileptiformes e também da dupla de redes destinada especificamente à detecção de eventos epileptogênicos (RNA1 e RNA2), já que as saídas das duas redes são, na realidade, cruzadas no algoritmo de detecção.

Novamente selecionou-se um conjunto de 27 canais (3 vetores com durações de 15 segundos, de cada arquivo de paciente), o qual foi condicionado e submetido a cada uma das redes neurais.

Cada um dos 405 segundos ( $27 \times 15$ ) foi apresentado às redes (RNA1, RNA2, RNA3, RNA4 e conjunto RNA1+RNA2) de forma que se obteve 2025 saídas *booleanas*, referentes à detecção positiva ou negativa de espículas, ondas agudas, ruídos e piscadas. Caso a saída da rede fosse maior que 0,7 a detecção seria considerada positiva. Caso fosse menor ou igual, a detecção seria considerada negativa. Os resultados estão resumidos nas tabelas abaixo.

A análise foi bastante rigorosa com respeito à precisão da detecção das redes RNA1 e RNA2, ou seja, mesmo um evento epileptiforme presente no sinal que não fosse evidentemente epileptogênico (aquele tipo de evento classificado como “possivelmente epileptiforme”), caso não fosse detectado pela rede seria contabilizada mais uma detecção falsamente negativa. A situação contrária também foi verdade: eventos epileptiformes tão morfologicamente próximos a espículas que só podem ser identificados como não-epileptogênicos com maior grau de certeza, através de análise visual dos demais canais e de instantes de tempo anteriores e posteriores, caso fossem detectados como positivos esta detecção era considerada falsamente positiva, apesar de poder não o ser.

Em resumo, todas as detecções positivas e negativas, realizadas sobre eventos “possivelmente epileptogênicos” foram contabilizadas como falsas, para garantir rigor na avaliação do sistema.

Deve-se observar que, no conjunto de testes com 27 arquivos selecionados aleatoriamente, apenas um continha ruído de grandes amplitude e energia, ou seja, do tipo que pode gerar detecções errôneas por assemelhar-se morfologicamente às espículas. Assim, a rede para reconhecimento de ruídos forneceu saídas com detecções positivas exatamente neste arquivo. É interessante salientar que 10 sinais do conjunto de testes, ou 37% dos arquivos, continham espículas, as quais foram detectadas corretamente pela rede de reconhecimento de ruídos como



negativas. Alguns arquivos possuíam inclusive poliespículas, as quais são bastante semelhantes a ruídos musculares, mas que a rede conseguiu detectar como não-ruídosos.

Já a rede RNA4 forneceu muitas saídas falsamente positivas pois classificou como piscadas várias ondas lentas de polaridades positivas, mesmo que não devidas a movimentos oculares, como as ondas delta.

Tabela 6.2: Resultados dos Testes com o Módulo de Análise Neural para as redes RNA1 (detecção de espículas) e RNA2 (detecção de ondas rápidas agudas). A rede RNA1 foi mais seletiva (92,3% de especificidade) e a rede RNA2 apresentou um valor de sensibilidade mais satisfatório (73,1%), porém não foi tão seletiva quanto aos eventos detectados como a RNA1. As taxas de acerto médio foram de 88,6% para a RNA1 e de 77,3% para a RNA3.

Arquivos de Teste				RNA1 Threshold =0.7					RNA2 Threshold=0.7				
Arq.	Pac.	Arquiv	Canal	VP	FP	VN	FN	Taxa Acerto	VP	FP	VN	FN	Taxa Acerto
1	8	630	6	4	1	8	2	80,0	5	1	8	1	86,7
2	4	2460	11	4	0	11	0	100,0	3	2	9	1	80,0
3	4	4260	4	0	0	15	0	100,0	0	5	10	0	66,7
4	5	3135	23	0	4	11	0	73,3	0	8	7	0	46,7
5	2	4725	8	0	1	13	1	86,7	1	7	7	0	53,3
6	9	3600	28	0	0	14	1	93,3	0	0	14	1	93,3
7	2	4425	14	0	1	13	1	86,7	0	7	8	0	53,3
8	7	3720	12	0	0	15	0	100,0	0	1	14	0	93,3
9	2	1035	14	0	5	10	0	66,7	0	11	4	0	26,7
10	5	2940	13	2	0	7	6	60,0	6	1	6	2	80,0
11	5	1485	22	0	6	9	0	60,0	0	4	11	0	73,3
12	3	180	23	0	0	15	0	100,0	0	0	15	0	100,0
13	9	2985	13	0	0	15	0	100,0	0	4	11	0	73,3
14	6	2655	13	0	0	15	0	100,0	0	3	12	0	80,0
15	4	5430	26	0	0	13	2	86,7	1	0	13	1	93,3
16	8	1335	20	0	0	15	0	100,0	0	2	13	0	86,7
17	3	1980	30	0	0	15	0	100,0	0	0	15	0	100,0
18	6	1425	21	0	0	14	1	93,3	1	5	9	0	66,7
19	7	2775	25	0	0	15	0	100,0	0	2	13	0	86,7
20	7	2625	4	0	0	15	0	100,0	0	3	12	0	80,0
21	1	3090	23	0	0	15	0	100,0	0	4	11	0	73,3
22	8	315	31	0	0	13	2	86,7	1	3	10	1	73,3
23	6	915	28	0	0	15	0	100,0	0	1	14	0	93,3
24	9	4080	26	0	0	15	0	100,0	0	0	15	0	100,0
25	3	1725	20	0	0	14	1	93,3	1	0	14	0	100,0
26	1	3600	24	0	0	15	0	100,0	0	5	10	0	66,7
27	1	2400	15	0	11	4	0	26,7	0	6	9	0	60,0
Somatórios:				10	29	349	17	88,6	19	85	294	7	77,3
				Sensibilidade:				37,0	Sensibilidade:				73,1
				Especificidade:				92,3	Especificidade:				77,6



Tabela 6.3: Resultados dos Testes com o Módulo de Análise Neural para as redes RNA3 (detecção de artefatos e ruídos) e RNA4 (detecção de piscadas e movimentos oculares).

Arquivos de Teste				RNA3 Threshold =0.7					RNA4 Threshold=0.7				
Arq.	Pac.	Arquiv	Canal	VP	FP	VN	FN	Taxa Acerto	VP	FP	VN	FN	Taxa Acerto
1	8	630	6	0	0	15	0	100,0	0	11	4	0	26,7
2	4	2460	11	0	0	15	0	100,0	0	10	5	0	33,3
3	4	4260	4	0	0	15	0	100,0	2	5	6	2	53,3
4	5	3135	23	0	0	15	0	100,0	1	2	11	1	80,0
5	2	4725	8	0	0	15	0	100,0	9	2	0	4	60,0
6	9	3600	28	0	0	15	0	100,0	0	2	13	0	86,7
7	2	4425	14	0	0	15	0	100,0	1	5	9	0	66,7
8	7	3720	12	0	0	15	0	100,0	0	3	12	0	80,0
9	2	1035	14	0	0	15	0	100,0	3	6	5	1	53,3
10	5	2940	13	0	0	15	0	100,0	0	6	9	0	60,0
11	5	1485	22	0	0	15	0	100,0	1	5	8	1	60,0
12	3	180	23	0	0	15	0	100,0	0	0	15	0	100,0
13	9	2985	13	0	0	15	0	100,0	0	1	14	0	93,3
14	6	2655	13	0	0	15	0	100,0	0	2	13	0	86,7
15	4	5430	26	0	0	15	0	100,0	0	1	14	0	93,3
16	8	1335	20	0	0	15	0	100,0	0	4	11	0	73,3
17	3	1980	30	0	0	15	0	100,0	0	0	15	0	100,0
18	6	1425	21	0	0	15	0	100,0	0	5	10	0	66,7
19	7	2775	25	0	0	15	0	100,0	0	2	13	0	86,7
20	7	2625	4	0	0	15	0	100,0	0	2	13	0	86,7
21	1	3090	23	0	0	15	0	100,0	0	4	11	0	73,3
22	8	315	31	0	0	15	0	100,0	0	1	14	0	93,3
23	6	915	28	0	0	15	0	100,0	0	1	14	0	93,3
24	9	4080	26	0	0	15	0	100,0	0	1	14	0	93,3
25	3	1725	20	0	0	15	0	100,0	0	0	15	0	100,0
26	1	3600	24	0	0	15	0	100,0	0	1	14	0	93,3
27	1	2400	15	8	0	0	7	53,3	6	3	3	3	60,0
Somatórios:				8	0	390	7	98,3	23	85	285	12	76,0
				Sensibilidade:				53,3	Sensibilidade:				65,7
				Especificidade:				100,0	Especificidade:				77,0



Tabela 6.4: Resultados dos Testes com o Módulo de Análise Neural para o conjunto formado pelas redes RNA1 e RNA2 – detecção de espículas e ondas agudas. Os valores de sensibilidade e especificidade assumiram valores intermediários aos assumidos individualmente pelas duas redes.

Arquivos de Teste				RNA1+RNA2 Threshold=0.7				
Arg.	Pac.	Arquiv	Canal	VP	FP	VN	FN	Taxa Acerto
1	8	630	6	6	1	8	0	93,3
2	4	2460	11	4	1	9	1	86,7
3	4	4260	4	0	1	10	4	66,7
4	5	3135	23	0	5	10	0	66,7
5	2	4725	8	1	6	8	0	60,0
6	9	3600	28	0	0	12	3	80,0
7	2	4425	14	1	1	12	1	86,7
8	7	3720	12	0	1	14	0	93,3
9	2	1035	14	0	8	7	0	46,7
10	5	2940	13	4	0	7	4	73,3
11	5	1485	22	0	3	12	0	80,0
12	3	180	23	0	0	15	0	100,0
13	9	2985	13	0	0	15	0	100,0
14	6	2655	13	0	3	12	0	80,0
15	4	5430	26	1	0	13	1	93,3
16	8	1335	20	0	1	14	0	93,3
17	3	1980	30	0	0	15	0	100,0
18	6	1425	21	0	3	11	1	73,3
19	7	2775	25	0	1	14	0	93,3
20	7	2625	4	0	3	12	0	80,0
21	1	3090	23	0	3	12	0	80,0
22	8	315	31	1	1	12	1	86,7
23	6	915	28	0	1	14	0	93,3
24	9	4080	26	0	0	15	0	100,0
25	3	1725	20	1	0	14	0	100,0
26	1	3600	24	0	5	10	0	66,7
27	1	2400	15	0	9	6	0	40,0
Somatórios:				19	57	313	16	82,0
				Sensibilidade: 54,3				
				Especificidade: 84,6				

Por fim, como se esperava, a associação das saídas das redes RNA1 e RNA2 forneceu valores “médios” de sensibilidade e especificidade em relação aos valores obtidos com cada uma das redes, individualmente.

Isto porque a rede RNA1 provou ser menos sensível que a RNA2, já que o objetivo era, realmente, uma maior certeza na detecção positiva (especificidade), em detrimento da capacidade da rede em detectar todos os eventos de interesse (sensibilidade). A rede RNA1 apresentou sensibilidade de 37,0% e a rede RNA2, 73,1%, enquanto a associação das duas redes apresentou sensibilidade de 54,3%. Ou seja, um valor intermediário entre as sensibilidades individuais de ambas as redes.



Já a capacidade de detectar apenas eventos realmente relevantes na rede RNA1 foi expressivamente maior (92,3%) que na rede RNA2 (77,6%), pois esta última tende a confundir as espículas e ondas *sharp* com movimentos oculares. Assim, a rede RNA2 “puxou para baixo” o desempenho do conjunto das duas redes, que apresentou especificidade igual a 84,6%.

A Taxa de acerto do conjunto permaneceu acima de 80% (mais especificamente, 82,0%).

### 6.3 Procedimento de Teste Geral do Sistema

Para testar o desempenho geral, a sensibilidade e a especificidade do sistema SIDAPE integralmente, adotou-se o seguinte procedimento:

- 1) Para um dado paciente, selecionar aleatoriamente 3 telas contínuas de 15 segundos (uma tela “atual”, uma anterior e uma posterior à atual);
- 2) Verificar todas as detecções com resultados: Verdadeiro-Positivo (VP), Verdadeiro-Negativo (VN), Falso-Positivo (FN) e Falso-Negativo (FNP), para cada um dos  $3 \times 15 = 45$  segundos de cada um dos 32 canais (ou 24, no caso do paciente 5). Número Total de saídas testadas:  $45 \times 32 = 1440$  saídas (ou  $45 \times 24 = 1080$  saídas para o paciente 5).
- 3) Repetir este procedimento mais 9 vezes para o mesmo paciente (14400 saídas testadas/paciente, ou 10800 saídas/paciente 5);
- 4) Repetir este procedimento para os demais 8 registros de paciente.

Ou seja, ao final desta bateria de testes, haviam sido testadas 126.000 saídas no sistema.

É importante salientar que:

- Espículas “duvidosas” eram marcadas sempre em prejuízo do sistema para garantir confiabilidade nos testes. Isto é, se o sistema as detectasse, seria contabilizada uma marcação falsamente positiva; se não as detectasse, seria contabilizada uma marcação falsamente negativa;
- Os testes foram realizados em relação a cada época de um segundo, e não em relação a cada espícula individualmente. Ou seja, caso existisse mais de uma espícula em um determinado segundo, apenas uma saída seria considerada positiva. Isto porque pode ser impraticável contabilizar-se todas as espículas em alguns arquivos, principalmente quando ocorrem eventos

poliespícula-onda. Além disto este é o intervalo de análise do SIDAPE e considera-se que uma saída positiva já é indicativo suficiente da ocorrência de ao menos um evento espicular naquele segundo.

Os resultados obtidos estão resumidos na Tabela 6.5.

A sensibilidade do SIDAPE mostrou-se baixa (48,7%). Isto pode ser creditado ao fato de se ter priorizado maiores confiabilidade e certeza nas marcações, principalmente para detecções positivas. Isto fez com que o sistema se tornasse consideravelmente rigoroso em marcar um evento como espícula. É interessante notar que o paciente 4, cujo registro era mais livre de artefatos que os dos demais pacientes, apresentou um valor superior de sensibilidade.

Já a especificidade alcançou valores altos para todos os pacientes, e um valor médio de 98,4%.

Para o teste geral do sistema, calculou-se também o Valor Preditivo Positivo (VPP) e o Valor Preditivo Negativo do sistema. O parâmetro Valor Preditivo Positivo estima a probabilidade de um paciente ser portador de um determinado diagnóstico (no caso do SIDAPE: probabilidade de o registro de EEG apresentar, de fato, uma espícula), se o sistema disser que realmente o paciente apresenta este diagnóstico (se o SIDAPE gerar uma detecção positiva para espícula). O VPP foi de 47,3% para o sistema SIDAPE. E o Valor Preditivo Negativo foi calculado em 97,4% para o SIDAPE e estima a probabilidade de um paciente não ser portador de um determinado diagnóstico (ou de um registro de EEG não apresentar espículas), se o sistema afirmar que o paciente não apresenta este diagnóstico (se o SIDAPE gerar uma detecção negativa para espícula na época).

A taxa de acertos média do SIDAPE alcançou o valor satisfatório de 96,2%. As maiores fontes de marcações falsamente positivas foram as piscadas, os ruídos musculares, o ritmo alfa e os fusos do sono, nesta ordem de importância.

Tabela 6.5: Resultados dos testes realizados com o sistema SIDAPE em 126.000 trechos (com 1 segundo cada, de duração) de registros de EEG de 9 pacientes.

PACI- ENTE	No. DE SEG.s	VP	FP	VN	FN	SENS.	SEL.	VPP	VPN	TAXA DE ACERTO
1	14.400	294	243	13328	535	35,5	98,2	54,7	96,1	94,6
2	14.400	85	206	14040	69	55,2	98,6	29,2	99,5	98,1
3	14.400	58	299	14007	36	61,7	97,9	16,2	99,7	97,7
4	14.400	814	252	12886	448	64,5	98,1	76,3	96,6	95,1
5	10.800	826	222	8799	953	46,4	97,5	78,8	90,2	89,1
6	14.400	70	92	14112	126	35,7	99,4	43,2	99,1	98,5
7	14.400	92	113	14077	118	43,8	99,2	44,8	99,1	98,4
8	14.400	435	215	13364	386	53,0	98,4	66,9	97,1	95,8
9	14.400	33	186	14137	44	42,9	98,7	15,0	99,7	98,4
VALORES MÉDIOS [%]:						<b>48,7</b>	<b>98,4</b>	<b>47,3</b>	<b>97,4</b>	<b>96,2</b>



## 7. DISCUSSÕES

O presente capítulo explora algumas das discussões que se considerou as mais importantes e as mais frequentemente levantadas ao longo do trabalho.

### 7.1 Sobre a utilização de valores arbitrários ou empíricos

Alguns dos sistemas mais bem-sucedidos na detecção automática de espículas em EEG, como os sistemas de Gotman e Gloor [54] e de Lopes da Silva et. al. [37] partiram de definições quantitativas, empíricas, de espícula. Arbitram-se, por exemplo, parâmetros de durações para os períodos de subida e descida da espícula, valores absolutos e relativos de amplitudes, valores para derivadas de primeira e segunda ordem, etc. Estes parâmetros são baseados em características físicas dos sinais, porém estas características variam substancialmente de indivíduo para indivíduo. Este tipo de definição, então, é construída com base na experiência de cada grupo de trabalho e portanto é de difícil reprodução. Além disto, como colocam Kalayci, Özdamar [77] e Webber et. al. [138], ainda não se pode determinar quais são os parâmetros relevantes e suficientes para se descrever uma espícula.

No presente trabalho evitou-se arbitrar valores para descrever espículas, embora alguns parâmetros tenham que ser obrigatoriamente assumidos como valores de *thresholds* para decisões do sistema e valores de crença para as regras de decisão. A preocupação maior porém foi em manter ao máximo a análise quantitativa restrita aos valores de saída do sistema e evitar assunções empíricas diretamente sobre sinais de EEG e seus eventos típicos.

Enfim, além do SIDAPE, todos os sistemas de detecção automática de espículas estudados [9][50][54][68][77][106][130][131][139] utilizaram um ou mais valores arbitrários para fornecer saídas do sistema, pois o computador não tem habilidade de analisar variáveis qualitativas.

Sobre a utilização de classificação qualitativa sobre espículas (como “Perfeitas”, “Comuns”, “Ordinárias”, “Definitivamente Epileptiformes”, “Possivelmente Epileptiformes”, etc), considera-se que seja necessária já que nem toda a espícula é indiscutível. Ou seja, dada a variabilidade na morfologia das mesmas há que se ter um critério para diferenciar aqueles eventos que seriam considerados espículas, na maior parte das avaliações, daqueles eventos mais

controversos. E este critério será utilizado na implementação do sistema automático, tal como foi feito no SIDAPE e nos sistemas de Webber et. al. [139] e Pradhan et. al. [106], por exemplo.

## 7.2 Sobre a Análise *Wavelet*

Uma das maneiras de se evitar analisar diretamente as características físicas dos sinais de EEG e sem fazer parametrização, seria o pré-processamento por meio de uma Transformação, como foi feito no SIDAPE.

E parece haver um senso comum entre os pesquisadores da área de que, caso seja utilizada uma transformada para processar o sinal de EEG, a função *kernel* desta deve guardar alguma semelhança morfológica com as espículas, de forma a aumentar o grau de correlação. Stelle e Comley [130] utilizaram a função Impulso por esta razão. Attelis et. al. [9] utilizaram a função Biortogonal na decomposição dos sinais de EEG, por considerarem-na de melhor localização e custo mínimo, com relação à STFT. Kalayci e Özdamar [77] avaliaram duas funções *wavelet* de Daubechies para verificar se haveria diferença nos resultados e recomendaram a investigação de outras funções. Dümpelmann e Elger [42] pontuaram a importância de se utilizar uma função *Wavelet* com alta similaridade em relação a espículas e confirmaram as Coiflets como sendo tais funções.

O presente trabalho, no entanto, coloca esta questão como fundamental e realiza toda uma investigação para encontrar uma função que forneça maior correlação com as espículas. E isto serve também para justificar o uso da Transformada *Wavelet*, pois esta permite a flexibilização na escolha da função *kernel*.

Além disto, a Transformada *Wavelet* permitiu maior compactação nos dados, melhores definições em tempo e frequência e menor custo computacional em relação às outras transformadas, tal como esperado.

É muito importante salientar também que o uso da função Coiflet1, na FWT, diminuiu a influência do ritmo alfa sobre os sinais reconstruídos, evento este que normalmente é uma grande fonte de erros na detecção, em sistema automáticos.



### 7.3 Sobre a Análise Neural

A escolha por utilizar redes neurais artificiais na detecção de espículas pareceu lógica para este trabalho porque, uma vez treinadas, as RNAs apresentam capacidade de generalizar sobre os dados, o que é fundamental quando se tem muita variabilidade nos mesmos e se quer implementar um sistema de considerável aplicabilidade.

Além disto, é sempre mais fácil obter-se um conjunto de treinamento que se extrair conhecimentos e regras a partir dos dados, ainda mais quando não há especialistas de domínio à disposição.

Além das MLPs, outras topologias de redes como as redes *Feedforward* com Dinâmicas de Entrada [114][78], a Rede Neural Probabilística - PNN [125][126][127] e as Redes *Neocognitron* de Fukushima [48][49], as quais podem ser consideradas adequadas à tarefa de classificação de padrões, foram também estudadas e investigadas neste trabalho. Suas utilizações, porém, foram descartadas devido principalmente à inadequação das características das redes, em relação à forma de apresentação dos sinais de EEG que se queria utilizar. Por exemplo, as redes *Neocognitron* utilizam entradas bidimensionais (matrizes de *pixels*, por exemplo), quando o sinal de EEG é unidimensional. Já a Rede Probabilística trabalha com estimativas de Funções Densidade de Probabilidade dos padrões a serem analisados. Porém, a utilização deste tipo de rede demandaria um longo estudo do espaço de probabilidades de padrões de entrada em sinais de EEG, razão pela qual optou-se por deixar esta investigação como sugestão de trabalho futuro (vide Capítulo 9).

Além da topologia de rede neural artificial Feedforward, foram implementadas e testadas 3 redes do tipo Mapa Auto-Organizável de Kohonen, MAK, utilizando os mesmos procedimentos de transformação e condicionamento e uma rede do tipo Vetor de Quantização Linear, LVQ, as quais sempre ofereceram resultados inferiores às redes MLP<sup>25</sup>.

Em relação às duas redes projetadas para o reconhecimento de eventos epileptogênicos, RNA1 e RNA2, observando-se as Tabelas 6.2 e 6.3 fica claro que a segunda rede, treinada para reconhecer eventos mais lentos (ondas agudas) que as espículas, apresentou um valor de sensibilidade mais adequado (73,1%) que a sensibilidade apresentada pela rede de reconhecimento de espículas, RNA1 (com apenas 37,0% de sensibilidade). Porém esta última foi mais seletiva em suas detecções positivas (92,3% de especificidade), enquanto a RNA2 foi mais susceptível a

---

<sup>25</sup> Devido à grande quantidade de dados manipulados, a apresentação quantitativa dos resultados obtidos em todos os testes preliminares seria absolutamente inviável, dado o tempo que deveria ser despendido na documentação destes dados e dado o aumento na extensão do presente documento, caso isto fosse feito. Demonstrações destes resultados serão, então, deixados de lado neste trabalho, mas o leitor mais interessado poderá obtê-los com a autora por um dos e-mails: [fernanda@gpeb.ufsc.br](mailto:fernanda@gpeb.ufsc.br) e [fernanda@univale.br](mailto:fernanda@univale.br).



eventos como artefatos oculares e ritmo alfa, que possuem componentes de frequência menores, mais próximos às componentes das ondas agudas. Assim, para fornecer um equilíbrio ao sistema, ambas as saídas das redes são consideradas na detecção, com pesos iguais.

Já os desempenhos das outras duas RNAs (3 e 4), os quais podem ser conferidos na Tabela 6.3, são satisfatórios mas de importância secundária, pois estas redes servem para fornecer informações complementares ao sistema, para auxiliar a confirmar ou rejeitar a detecção de espículas.

## 7.4 Sobre as Regras de Produção

Alguns dos sistemas estudados também utilizaram regras para decisão [54][139], ao invés de variáveis simples, em uma tentativa de simular o comportamento humano.

Alguns autores [54][139] salientam também a importância de se considerar a reversão de fase em um sistema automático de detecção de espículas que considere mais que um canal na análise, como o SIDAPE. A análise de canais adjacentes, pertencentes ao mesmo laço bipolar do canal suspeito de apresentar uma espícula aumenta a confiança na rejeição ou confirmação deste evento, tal como faria um eletroencefalografista humano.

As regras de produção no SIDAPE foram implementadas principalmente com o objetivo de diminuir as detecções falsamente positivas (aumentar a especificidade do sistema), as quais costumam ser apontadas como pontos fracos nos sistemas de detecção automática [106][130]. E este objetivo pode ser considerado atingido quando se observa que a especificidade do sistema em relação à detecção de espículas antes da Base de Regras (seletividade do conjunto RNA1 + RNA2) era de 84,6% e aumentou para 98,4% após a análise neste módulo do sistema.

## 7.5 Sobre os resultados

Em uma primeira análise, o valor baixo de sensibilidade poderia desmerecer o sistema. A avaliação da validade e do desempenho de um sistema, no entanto, não pode passar apenas por uma leitura dos números não interpretados, principalmente se este sistema utiliza ferramentas de Inteligência Artificial e se será aplicado à análise de sinais bioelétricos. Vários pontos devem ser ressaltados de forma a justificar os baixos valores de sensibilidade e valor preditivo positivo do sistema:

- Se a Precisão do sistema for calculada como média aritmética entre a Sensibilidade e Especificidade, como feito por Kalayci e Özdamar [77], o SIDAPE atinge o valor de 73,55% de precisão, valor que pode ser considerado bastante satisfatório para um sistema que se propõe a fazer uma redução de dados, um auxílio à análise posterior, por parte do eletroencefalografista;

- Caso seja alterado o peso de ativação de saída das redes (que é o mesmo para as redes RNA1 e RNA2), em função dos valores de sensibilidade, com certeza se teria obtido um valor maior neste índice, em detrimento da especificidade. Gabor e Seyal [50], por exemplo, treinaram duas redes para reconhecimento de espículas (uma para reconhecer o período pré-pico e a outra, para o período pós-pico da espícula) e ajustaram o valor final de certeza na detecção, calculado como combinação de ativações ponderadas de saída das duas redes, em função da sensibilidade, para atingir 94,2% neste índice. O mesmo efeito seria obtido diminuindo-se o valor de qualquer um dos *thresholds* do sistema. Kalayci e Özdamar, por exemplo, obtiveram inicialmente valores de sensibilidade (38,4%) e especificidade (90,9%) bastante compatíveis com os obtidos no SIDAPE. Optaram, porém, por ajustar os parâmetros do sistema de forma a atingir um ponto médio de 73,6% nos dois índices. Como o objetivo no presente trabalho, porém, era obter-se maior certeza nas detecções positivas do sistema, optou-se por não utilizar estes artifícios;

- Os resultados foram obtidos analisando-se telas de 15 segundos e calculando-se a sensibilidade como função do número de detecções de espículas. Porém, sistemas de detecção automática de espícula são aplicáveis a registros de 30 minutos, no mínimo. E o SIDAPE foi construído pensando-se em monitoração de longo termo, com muitas horas de registro. Isto significa que o sistema disporá de 120 telas, no mínimo, para encontrar uma espícula. E se for considerada a capacidade geral do sistema em fornecer um valor positivo ou negativo para existência de espículas, ou seja, se for calculado o valor de sensibilidade no limite, ao longo de toda a duração do registro, este valor de sensibilidade tenderá a 100%. Isto porque o sistema acusou todos os pacientes da base de dados como portadores de espículas, o que o são, de fato. Em outras palavras, se houverem pelo menos duas espículas em todo o registro, o sistema será capaz de fornecer o diagnóstico de existência de espículas. No caso da análise de registros de longa duração, ou bastante além de 15 segundos, o EEG terá comportamento não-estacionário e provavelmente sofrerá considerável influência de ruídos musculares, movimentos oculares, ritmo alfa, etc. Ora, estes eventos são grandes fontes geradoras de falsos-positivos em sistemas automáticos, como visto no Capítulo 4. E isto faz com que a especificidade seja o parâmetro mais importante a ser considerado nos sistemas, porque vai garantir que eventos não-epileptogênicos não sejam marcados constantemente como positivos. E a maior disponibilidade de janelas de

tempo levará a sensibilidade a tender a 100%, no limite. Em resumo, se o sistema puder garantir que o evento encontrado é uma espícula (e o faz com 98,4% de certeza) e dispuser de um tempo suficiente de registro para garantir que a encontrará, se houver, os objetivos do trabalho terão sido atingidos;

- O grau de concordância entre dois especialistas na classificação de espículas é menor que 50%, como já foi observado por Dümpelmann e Elger [42], em 1999, por Hostetler et. al. [69], em 1992 e por Wilson et. al. [143], em 1996. Ou seja, se dois eletroencefalografistas experientes selecionarem conjuntos de 100 espículas cada um, a partir de um dado registro, menos de 50 eventos serão comuns aos dois conjuntos. É bastante razoável, portanto, que sistemas automáticos de detecção atinjam índices de desempenho inferiores a este, sem contar que não existe um padrão de definição sobre o que seja espícula para que se possa medir exatamente detecções “corretas” ou “erradas”. Sistemas que fornecem valores de sensibilidade e especificidade superiores talvez não obtivessem os mesmos resultados para um conjunto de testes diferente ou maior, por exemplo.



## 8. CONCLUSÕES

### 8.1 Com relação ao sistema

Um sistema automático com as características do SIDAPE, pode vir a ser de grande utilidade na prática do diagnóstico de Epilepsia. Este sistema irá auxiliar os eletroencefalografistas detectando os eventos epileptogênicos claros e evitando que os mesmos despendam inúmeras horas em revisões de EEGs. Utilizando o SIDAPE o revisor limita-se a analisar as janelas pré-marcadas pelo programa, poupando-se um tempo considerável deste profissional.

O tempo de processamento do SIDAPE, sobre os sinais “crus” de EEG digitalizados foi aproximadamente igual ao tempo de registro, em um microcomputador Pentium II, 500 MHz com 64 MBytes de memória RAM. Ou seja, o programa demora entre 10 a 15 segundos para analisar cada janela de 15 segundos com 32 canais. Esta velocidade inviabiliza a análise *on-line* que, no entanto, não é necessária para este tipo de tarefa, como já foi discutido no Capítulo 5. E este desempenho de velocidade só pode ser atingido devido à utilização dos *thresholds*, de redes neurais pré-treinadas e do algoritmo rápido FWT até o nível 3 apenas, os quais agilizaram consideravelmente o processamento.

Obviamente o SIDAPE está restrito aos índices de desempenho discutidos no Capítulo anterior. Contudo, considera-se que estes índices obtidos estão em pleno acordo com os objetivos pretendidos desde o início do trabalho. Também é sabido que mesmo eletroencefalografistas experientes tendem a concordar entre si em menos de 50% das detecções positivas. Ou seja, em média 5 espículas a cada 10 são ambíguas, duvidosas, difíceis de se classificar visualmente. Isto significa que a sensibilidade do SIDAPE é bastante coerente com a realidade, já que seria impossível avaliar-se o desempenho de um sistema “inteligente” como superior ao desempenho da inteligência que o projetou.

É importante salientar também que o problema da detecção falsamente positiva, em relação à falsamente negativa, pode ser considerado mais grave, já que uma espícula “perdida” no processo de detecção pode ser substituída por várias outras detectadas com alto grau de certeza, inclusive no mesmo instante de segundo, o que ainda caracteriza uma detecção verdadeiramente positiva. No entanto, uma detecção falsa pode acarretar até um diagnóstico errôneo. Em decorrência disto, os vários *thresholds* e parâmetros do sistema foram sempre ajustados de forma que se minimizasse o número de detecções falsamente positivas, apesar de isto acarretar em perda

da detecção de várias espículas reais, às vezes óbvias e perfeitas visualmente, mas de difícil modelagem matemática. E esta é a principal razão dos baixos valores de sensibilidade do sistema.

Para tentar aumentar a precisão do sistema, porém, caberiam testes com um valor menor de *threshold* para o condicionamento dos sinais. Os resultados dos testes com o módulo de Transformação sugerem que o valor de *threshold* escolhido seja muito alto (7,0 desvios além da média), já que a sensibilidade do módulo foi baixa (65%). Deve-se explorar mais o valor deste limiar de forma que se atinja um ponto ótimo de sensibilidade e especificidade.

Em relação às condições de operação o SIDAPE, como todo equipamento, deve ser utilizado em circunstâncias apropriadas. Os sinais de EEG devem ser livres, ao máximo, de ruídos e artefatos; o registro deve ser de longo termo e com 24 canais ou mais, para que os resultados sejam confiáveis e precisos.

As maiores desvantagens que se identificou na metodologia empregada no SIDAPE foram:

- O SIDAPE não é capaz de identificar crises epilépticas eletroencefalográficas – estas crises têm uma morfologia simples (semelhante a uma onda dente-de-serra), porém semelhante à morfologia dos ruídos e do ritmo alfa. Além disto, em um segundo de registro onde exista uma crise eletroencefalográfica não há picos ou eventos que se destaquem do restante do trecho, mas sim uma seqüência de picos, de espículas. E todos os procedimentos no SIDAPE baseiam-se na ocorrência justamente de eventos discrepantes em relação à atividade de fundo. Por esta razão, o SIDAPE não é capaz de detectar a atividade regular e de pequena variância da crise eletrográfica.
- O SIDAPE só identifica um evento por segundo – isto significa que apenas uma espícula pode ser captada, mesmo que existam outras naquele determinado segmento (de 1 segundo de duração). Além disto, caso haja em um mesmo trecho um evento epileptiforme que pareça mais notável ao SIDAPE que um evento epileptogênico, este último será perdido em detrimento da detecção falsamente positiva do outro evento.

Alguns pontos positivos, além dos já descritos anteriormente, percebidos no método empregado no SIDAPE foram:

- Outros tipos de eventos que costumam interferir na detecção automática e mesmo visual, como Complexos K, fusos do sono, ondas agudas do vértex, etc, foram quase completamente anulados pela FWT.



- Levando-se em conta a repetibilidade dos resultados a Função *Wavelet*-Mãe Coiflet1 mostrou-se superior a todas as outras analisadas neste trabalho, no que se refere à sua adequação como ferramenta de detecção de espículas, em sinais de EEG. Este resultado vem de encontro ao que já tinha sido constatado empiricamente no trabalho da autora, em aplicações anteriores, e ao que Dümpelmann [42] utilizou, sem maiores detalhamentos, em seu trabalho de tese de Doutorado. Esta constatação abre uma série de discussões sobre a adequação de uma função *Wavelet* à aplicação pretendida.
- As interfaces gráficas do sistema permitem aos eletroencefalografistas “navegar” ao longo dos registros, alterando à vontade as escalas de amplitude e de tempo, de uma forma muito mais produtiva que a simples visualização dos registros em papel.

A implementação do sistema de detecção automática de espículas não pode ser considerada como concluída, absolutamente, devido às otimizações, adições e testes que se pretendia fazer ainda com o código. Todas estas tarefas deverão ser implementadas em uma etapa de continuação do trabalho.

Os atrasos na entrega de um sistema definitivo devem-se à abrangência, à dimensão extremamente grande do escopo, principalmente, mas também devido ao enorme tempo gasto até que se conseguisse uma base de dados para iniciar efetivamente o trabalho (aproximadamente 6 meses após a data da qualificação, em fevereiro de 1998) e ao fato de a autora ter trabalhado solitariamente, sem uma equipe de apoio que pudesse efetivar tarefas simples e rotineiras, mas longas e demoradas, como seleção de arquivos para treinamento, cálculos repetitivos, codificações de algoritmos, decodificações de sinais em vários formatos de arquivos, etc.

Entretanto, pode-se considerar o protótipo do sistema como de altos desempenho e confiabilidade, o que já valida o trabalho realizado. Também, dado que as etapas mais complexas e longas de desenvolvimento de *software*, a saber Análise de Requisitos e Projeto, foram finalizadas, as tarefas restantes teriam caráter mais braçal, de codificação em uma linguagem de computador de compilação e execução rápidas como a Linguagem C<sup>++</sup>.



## 8.2 Com relação às contribuições científicas

A autora vê como grande mérito deste trabalho a preocupação com a determinação de uma função *wavelet* adequada para uma tarefa específica, neste caso, a detecção de espículas. Em aplicações anteriores não havia a preocupação formal em se escolher uma função *wavelet* mais adequada ou não houve a iniciativa em se encontrar esta função, de uma maneira científica.

Em relação à tarefa de detecção automática de espículas, o SIDAPE apresentou uma arquitetura inovadora também por considerar outros eventos na classificação, além das próprias espículas e ondas agudas. Nenhum outro sistema do qual se tenha notícia analisou ruídos e movimentos oculares paralelamente à análise de espículas, de forma a efetivamente diminuir a influência das detecções falsamente positivas.

O SIDAPE destaca-se também, em relação a vários sistemas existentes, por analisar 32 canais simultaneamente e por marcar cada espícula individualmente nas telas de apresentação. Ou seja, sistemas comerciais existentes marcam todo o segmento de tempo, nos 32 canais, durante o qual ocorrem as espículas, sem discriminá-las propriamente. Isto faz, às vezes, com que o eletroencefalografista fique em dúvida sobre qual evento no registro levou à detecção positiva e sobre qual o canal onde uma espícula foi detectada. No SIDAPE as espículas são marcadas claramente, o que permite ao revisor decidir facilmente por rejeitar ou confirmar a hipótese fornecida pelo sistema. Além disto, o fato de o SIDAPE marcar cada espícula em cada canal facilita uma investigação acerca da delimitação do foco epiléptico.

## 9. SUGESTÕES PARA TRABALHOS FUTUROS

Apesar da extensão do trabalho desenvolvido e dos resultados satisfatórios alcançados, muita coisa poderia ainda ser agregada ao SIDAPE, de forma que se obtenha um sistema de detecção com taxas ainda mais altas de precisão e desempenho.

Acredita-se que esta manutenção a ser realizada no SIDAPE não demandaria um esforço e um custo consideráveis, já que grande parte do trabalho consistiria da implementação de pequenas e simples rotinas (com exceção dos trabalhos de investigação listados abaixo, os quais poderiam gerar outras linhas de pesquisa a nível de pós-graduação), as quais seriam adicionadas ao código final.

O trabalho atende, no entanto, a proposta inicial de fornecer o protótipo de sistema e as diretrizes e requisitos necessários ao desenvolvimento de um produto final. Os demais aprimoramentos serão deixados ao encargo de trabalhos futuros, que sigam a mesma linha de pesquisa.

Foram identificadas como possíveis alterações e incrementos importantes para aplicações futuras no SIDAPE:

- Determinação, utilizando-se o método comparativo de dispersão, das melhores bases *Wavelet* para eventos tipo ruído muscular e tipo movimentos oculares (EOG) e piscadas. Isto aumentará a especificidade das ANNs em relação aos eventos que estão individualmente encarregadas de reconhecer;
- Desenvolvimento de uma metodologia de derivação da função *wavelet* ótima, a partir do próprio padrão espicular ou;
- Investigação de outras funções *wavelet*, utilizando-se o método comparativo de dispersão, além das 47 já investigadas;
- Inclusão de regras mais sofisticadas de avaliação da ocorrência de “reversão de fase” (ou “campo”), tais como a verificação do ponto de ocorrência de cada pico epileptiforme encontrado e o cruzamento deste com os possivelmente encontrados em outros canais, para uma análise mais apurada;
- Inclusão de regras de produção na Base de regras fundamentadas nos Modelos de Gotman;

- Investigação do uso das Redes Neurais Probabilísticas e das Redes Neurais de Regressão Geral, desenvolvidas por Donald Specht [125][126][127], como classificadoras dos eventos ressaltados pela Transformada *Wavelet*. Estas redes são recomendadas, principalmente, por receberem como entrada parâmetros independentes da fase do evento (posição do evento, dentro da época, o qual varia em relação às posições para as quais a rede foi treinada);
- Inclusão de ajuste automático dos parâmetros e *thresholds* do sistema, de forma que seja dependente de fatores como amplitude média da época, horário do registro, entropia de frequências na época, etc ou;
- Ajuste dos parâmetros de classificação através de Norma Euclidiana;
- Realização de uma investigação mais apurada sobre a possibilidade de utilização dos coeficientes de decomposição *wavelet* (ao invés do sinal reconstruído) como entradas das ANNs e como forma de reduzir a dimensionalidade;
- Implementação de uma ANN específica para reconhecimento do evento crise epiléptica;
- Investigação da utilização da Transformada Matching Pursuit como pré-processamento para redes do tipo MAK, ou LVQ, quando surgir um algoritmo rápido para a MPT;
- Integração do sistema SIDAPE a um sistema digital de aquisição de sinais de EEG;
- Investigação da relação entre os fatores de crença nos eventos epileptiformes detectados a partir dos sinais reconstruídos dos detalhes 2 e dos detalhes 3, ou seja, ponderar as saídas das redes RNA1 e RNA2 de forma a aumentar a influência da primeira, já que o detalhe 2 é mais confiável na detecção que o detalhe 3.

A autora do trabalho tem intenção de continuar trabalhando nesta linha de pesquisa, realizando inclusive algumas das tarefas sugeridas acima.

Também recomenda que o Grupo de Pesquisas em Engenharia Biomédica, GPEB, do Departamento de Engenharia Elétrica da Universidade Federal de Santa Catarina leve este trabalho adiante, pois, uma vez concluído, poderá ter uma aplicabilidade prática muito grande na rotina de Clínicas Neurológicas do Brasil, tal como já é feito nos países desenvolvidos.



## ANEXO A - ALGORITMO FWT (*FAST WAVELET TRANSFORM - TRANSFORMADA WAVELET RÁPIDA*)

Seja  $\phi(j)$ , com  $j=1, \dots, J$ ; a função Escala correspondente à função *Wavelet*  $\psi$  que se deseja aplicar ao sinal  $s(i)$ , com  $i=1, \dots, I$ . Os passos a serem seguidos para implementação do algoritmo da FWT podem ser sumarizados como segue.

1. Computar os filtros de reconstrução  $H_R$  (passa-baixas),  $G_R$  (passa-altas) e de decomposição  $H_D$  (passa-baixas) e  $G_D$  (passa-altas), a partir de  $\phi$ :

- a. Normalizar  $\phi$ :

$$\phi_N(n) = \frac{\phi(n)}{\sum_{j=1}^J \phi(j)} \quad \text{para } n=1, \dots, J \quad (\text{Eq. A. 1})$$

- b. Calcular os filtros em quadratura de reconstrução:

$$H_R = \sqrt{2} \cdot \phi_N \quad \text{e} \quad (\text{Eq. A. 2})$$

$$G_R(n) = (-1)^{n-1} \cdot H_R(J-n+1) \quad \text{para } n=1, \dots, J \quad (\text{Eq. A. 3})$$

- c. Calcular os filtros em quadratura de decomposição:

$$H_D(n) = H_R(J-n+1) \quad \text{para } n=1, \dots, J \quad (\text{Eq. A. 4})$$

$$G_D(n) = G_R(J-n+1) \quad \text{para } n=1, \dots, J \quad (\text{Eq. A. 5})$$

2. Para cada nível de decomposição  $k$ , repita os passos 3 a 6.
3. Faça a convolução do sinal  $s$  com o Filtro de decomposição Passa-baixas  $H_D$  (Filtragem FIR digital). Analiticamente:

$$\begin{aligned} \text{Fir}_H(n-J) &= H_D(1)*s(n) + H_D(2)*s(n-1) + \dots + H_D(J+1)*s(n-J) \\ &, \text{ com } n=J+1, \dots, (J+I-1) \end{aligned} \quad (\text{Eq. A. 6})$$

4. Compute o vetor de coeficientes de aproximação fazendo a decimação (subamostragem por um fator de 2) de  $\text{Fir}_H$ :

$$C_k(n) = \text{Fir}_H(2n) \quad , \text{ com } n=1, \dots, (J+I-1)/2 \quad (\text{Eq. A. 7})$$

5. Faça a convolução do sinal  $s$  com o Filtro de decomposição Passa-altas  $G_D$ :

$$\text{Fir}_G(n-J) = G_D(1)*s(n) + G_D(2)*s(n-1) + \dots + G_D(J+1)*s(n-J)$$

$$, \text{ com } n=J+1, \dots, (J+I-1) \quad (\text{Eq. A. 8})$$

6. Compute o vetor de coeficientes de detalhe fazendo a decimação (subamostragem por um fator de 2) de  $Fir_G$ :

$$D_k(n) = Fir_G(2n) \quad , \text{ com } n=1, \dots, (J+I-1)/2 \quad (\text{Eq. A. 9})$$

As funções de escala podem ser obtidas em muitas referências bibliográficas relacionadas à construção e utilização de *Wavelets*. Porém a Tabela abaixo fornece diretamente alguns exemplos de filtros em quadratura, derivados de funções *wavelet* e escala ortogonais conhecidas (dispensando a implementação do passo 1 do algoritmo).

Tabela A. 1: FILTROS ORTOGONAIS DE DECOMPOSIÇÃO *WAVELET*

FAMÍLIA	ORDEM	PASSA-BAIXAS $H_D(t)$	PASSA-ALTAS $G_D(t)$
<i>Daubechies</i>	1 (Haar)	[0.7071 , 0.7071]	[-0.7071 , 0.7071]
	2	[-0.1294 , 0.2241 , 0.8365 , 0.4830]	[-0.4830 , 0.8365 , -0.2241 , -0.1294]
	3	[0.0352 , -0.0854 , -0.1350 , 0.4599 , 0.8069 , 0.3327]	[-0.3327 , 0.8069 , -0.4599 , -0.1350 , 0.0854 , 0.0352]
	4	[-0.0106 , 0.0329 , 0.0308 , - 0.1870 , -0.0280 , 0.6309 , 0.7148 , 0.2304]	[-0.2304 , 0.7148 , -0.6309 , -0.0280 , 0.1870 , 0.0308 , - 0.0329 , -0.0106]
	5	[0.0033 , -0.0126 , -0.0062 , 0.0776 , -0.0322 , -0.2423 , 0.1384 , 0.7243 , 0.6038 , 0.1601]	[-0.1601 , 0.6038 , -0.7243 , 0.1384 , 0.2423 , -0.0322 , - 0.0776 , -0.0062 , 0.0126 , 0.0033]
	6	[-0.0011 , 0.0048 , 0.0006 , - 0.0316 , 0.0275 , 0.0975 , - 0.1298 , -0.2263 , 0.3153 , 0.7511 , 0.4946 , 0.1115]	[-0.1115 , 0.4946 , -0.7511 , 0.3153 , 0.2263 , -0.1298 , - 0.0975 , 0.0275 , 0.0316 , 0.0006 , -0.0048 , -0.0011]
	7	[0.0004 , -0.0018 , 0.0004 , 0.0126 , -0.0166 , -0.0380 , 0.0806 , 0.0713 , -0.2240 , - 0.1439 , 0.4698 , 0.7291 , 0.3965 , 0.0779]	[-0.0779 , 0.3965 , -0.7291 , 0.4698 , 0.1439 , -0.2240 , - 0.0713 , 0.0806 , 0.0380 , - 0.0166 , -0.0126 , 0.0004 , 0.0018 , 0.0004]

	8	[-0.0001, 0.0007, -0.0004, -0.0049, 0.0087, 0.0140, -0.0441, -0.0174, 0.1287, 0.0005, -0.2840, -0.0158, 0.5854, 0.6756, 0.3129, 0.0544]	[-0.0544, 0.3129, -0.6756, 0.5854, 0.0158, -0.2840, -0.0005, 0.1287, 0.0174, -0.0441, -0.0140, 0.0087, 0.0049, -0.0004, -0.0007, -0.0001]
	9	[0.0000, -0.0003, 0.0002, 0.0018, -0.0043, -0.0047, 0.0224, 0.0003, -0.0676, 0.0307, 0.1485, -0.0968, -0.2933, 0.1332, 0.6573, 0.6048, 0.2438, 0.0381]	[-0.0381, 0.2438, -0.6048, 0.6573, -0.1332, -0.2933, 0.0968, 0.1485, -0.0307, -0.0676, -0.0003, 0.0224, 0.0047, -0.0043, -0.0018, 0.0002, 0.0003, 0.0000]
	10	[0.0000, 0.0001, -0.0001, -0.0007, 0.0020, 0.0014, -0.0107, 0.0036, 0.0332, -0.0295, -0.0714, 0.0931, 0.1274, -0.1959, -0.2498, 0.2812, 0.6885, 0.5272, 0.1882, 0.0267]	[-0.0267, 0.1882, -0.5272, 0.6885, -0.2812, -0.2498, 0.1959, 0.1274, -0.0931, -0.0714, 0.0295, 0.0332, -0.0036, -0.0107, -0.0014, 0.0020, 0.0007, -0.0001, -0.0001, 0.0000]
<i>Coiflets</i>	1	[-0.0157, -0.0727, 0.3849, 0.8526, 0.3379, -0.0727]	[0.0727, 0.3379, -0.8526, 0.3849, 0.0727, -0.0157]
	2	[-0.0164, -0.0415, 0.0674, 0.3861, -0.8127, 0.4170, 0.0765]	[-0.0594, -0.0237, 0.0056, 0.0018, -0.0007]
	3	[0.0000, -0.0001, 0.0005, 0.0011, -0.0026, -0.0090, 0.0159, 0.0346, -0.0823, -0.0718, 0.4285, 0.7938, 0.4052, -0.0611, -0.0658, 0.0235, 0.0078, -0.0038]	[0.0038, 0.0078, -0.0235, -0.0658, 0.0611, 0.4052, -0.7938, 0.4285, 0.0718, -0.0823, -0.0346, 0.0159, 0.0090, -0.0026, -0.0011, 0.0005, 0.0001, 0.0000]
	4	[0.0000, 0.0000, 0.0000, 0.0001, -0.0003, -0.0006, 0.0013, 0.0038, -0.0057, -0.0152, 0.0251, 0.0393, -0.0962, -0.0666, 0.4344, 0.7822, 0.4153, -0.0561, -0.0813, 0.0267, 0.0161, -0.0073, -0.0016, 0.0009]	[-0.0009, -0.0016, 0.0073, 0.0161, -0.0267, -0.0813, 0.0561, 0.4153, -0.7822, 0.4344, 0.0666, -0.0962, -0.0393, 0.0251, 0.0152, -0.0057, -0.0038, 0.0013, 0.0006, -0.0003, -0.0001, 0.0000, 0.0000, 0.0000]



	5	[0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0001, 0.0003, -0.0006, -0.0017, 0.0024, 0.0068, -0.0092, -0.0198, 0.0327, 0.0413, -0.1056, -0.0620, 0.4380, 0.7743, 0.4216, -0.0520, -0.0919, 0.0282, 0.0234, -0.0101, -0.0042, 0.0022, 0.0004, -0.0002]	[0.0002, 0.0004, -0.0022, -0.0042, 0.0101, 0.0234, -0.0282, -0.0919, 0.0520, 0.4216, -0.7743, 0.4380, 0.0620, -0.1056, -0.0413, 0.0327, 0.0198, -0.0092, -0.0068, 0.0024, 0.0017, -0.0006, -0.0003, 0.0001, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000]
<i>Symlet</i>	2	[-0.1294, 0.2241, 0.8365, 0.4830]	[-0.4830, 0.8365, -0.2241, -0.1294]
	8	[-0.0034, -0.0005, 0.0317, 0.0076, -0.1433, -0.0613, 0.4814, 0.7772, 0.3644, -0.0519, -0.0272, 0.0491, 0.0038, -0.0150, -0.0003, 0.0019]	[-0.0019, -0.0003, 0.0150, 0.0038, -0.0491, -0.0272, 0.0519, 0.3644, -0.7772, 0.4814, 0.0613, -0.1433, -0.0076, 0.0317, 0.0005, -0.0034]

**Observação 1:** Os filtros de Reconstrução  $H_R$  e  $G_R$  têm os mesmos valores que os filtros de Decomposição  $H_D$  e  $G_D$  em ordem invertida, ou seja:  $H_R(J - j + 1) = H_D(j)$ , onde  $J$  é o comprimento do vetor  $H_D$  e  $G_R(J - j + 1) = G_D(j)$ .

**Observação 2:** a tabela e observação 1 não valem para os filtros biortogonais, que possuem conjuntos de valores diferentes para a decomposição e a reconstrução.

## ANEXO B -*SOFTWARES* DE ANÁLISE *WAVELET* DE DOMÍNIO PÚBLICO OU *SHAREWARES*

<b>Pacote</b>	<b>Conteúdo</b>	<b>Desenvolvido por:</b>	<b>Endereço Internet ou outros</b>
Wavelet Workbench	IDL library derived from WaveLab	Amara Graps for Research Systems Inc.	<a href="http://www.amara.com/wwbdev/wwwbdev.html">http://www.amara.com/wwbdev/wwwbdev.html</a>
Khoros Wavelet and Compression Toolbox	Khoros toolbox	Computer Research and Applications Group, Laboratório de Los Alamos	<a href="http://www.c3.lanl.gov/~cjhamil/Wavelets/main.html">http://www.c3.lanl.gov/~cjhamil/Wavelets/main.html</a>
Matching Pursuit Package	Unix tools and C code	Stéphane Mallat e Zhifeng Zhang	<a href="ftp://cs.nyu.edu/pub/wave/software">ftp://cs.nyu.edu/pub/wave/software</a>
Mathematica Wavelet Programs	Mathematica programs	Jack Cohen, Tong Chen, Meng Xu	<a href="ftp://timna.Mines.edu/wavelets">ftp://timna.Mines.edu/wavelets</a>
MegaWave	Unix tools and C code	Jacques Froment	<a href="http://www.ceremade.dauph.ft/~mw">http://www.ceremade.dauph.ft/~mw</a>
Rice Wavelet Toolbox	Matlab toolkit	DSP Group, Rice University	<a href="http://jazz.rice.edu/software/RWT">http://jazz.rice.edu/software/RWT</a>
Uvi_Wave	For Matlab and Khoros 2	Signal Theory Group, Universidade de Vigo, Bayona-Vigo, Espanha	<a href="http://www.tsc.uvigo.es/~wavelets/uvi_wave.html">http://www.tsc.uvigo.es/~wavelets/uvi_wave.html</a>
W-Transform	Matlab toolkit	M. K. Kwong	<a href="ftp://info.mcs.anl.gov/pub/W-transform">ftp://info.mcs.anl.gov/pub/W-transform</a>
Waterloo Maple Software Wavelet Share Libraries	Maple wavelet library	Jacques Gelinias	<a href="ftp://daisy.uwaterloo.ca/pub/maple/5.3/share/daub">ftp://daisy.uwaterloo.ca/pub/maple/5.3/share/daub</a>
Wavelet at Imager	C routines	Bob Lewis	<a href="http://www.cs.ubc.ca/nest/imager/contributions/bobl/wvlt/top.html">http://www.cs.ubc.ca/nest/imager/contributions/bobl/wvlt/top.html</a>
WaveLab	Matlab toolkit	J. Buckheit, et. al.	<a href="http://playfair.stanford.edu:80/~wavelab/">http://playfair.stanford.edu:80/~wavelab/</a>
WaveLib	C library with Matlab interface	Mikael Bourges-Sevenier	<a href="http://www.sim.int-evry.fr/~bourges/WaveLib.html">http://www.sim.int-evry.fr/~bourges/WaveLib.html</a>
Wavelet Toolbox	Matlab toolkit	David Newland	(e-mail) <a href="mailto:den@eng.cam.ac.uk">den@eng.cam.ac.uk</a>
Wavelet Toolbox in Khoros	Khoros toolbox	Jonio Cavalcanti e Ramiro Jordon	<a href="ftp://ftp.khoros.com/pub/khoros/Khoros2/contrib/toolboxes/wavelet">ftp://ftp.khoros.com/pub/khoros/Khoros2/contrib/toolboxes/wavelet</a>
Wavelets for Kids	Mathematica notebook	Peter Mueller e Brani Vidakovic	<a href="ftp://ftp.isds.duke.edu/pub/Users/brani/papers">ftp://ftp.isds.duke.edu/pub/Users/brani/papers</a>
WaveThresh	S-Plus library	Guy Nason	<a href="http://www.stats.bris.ac.uk/pub/software/wavethresh/WaveThresh.html">http://www.stats.bris.ac.uk/pub/software/wavethresh/WaveThresh.html</a>
XWPL	X Window system	Fazal Majid	<a href="http://pascal.math.yale.edu/pub/wavelets/software/xwpl/html/xwpl.html">http://pascal.math.yale.edu/pub/wavelets/software/xwpl/html/xwpl.html</a>

## **ANEXO C – DETALHES ACERCA DOS REGISTROS DE EEG COMPONENTES DA BASE DE DADOS DE TREINAMENTO E TESTES DO SIDAPE**

### **Estrutura dos Registros Originais:**

O sistema Harmonie<sup>®</sup> armazena em um único arquivo (de texto, com extensão \*.EEG ou binário, com extensão \*.SIG) as seguintes informações:

CABEÇALHO 1 – contém dados sobre o paciente (Nome, Número de Identificação, Comentários), sobre o registro de EEG (Hora de início, Data de início, Montagem utilizada, Ganho médio, Desvio médio, Indicador de Calibração, Indicador de Marcação, Frequências de corte inferior e superior do filtro passa-bandas, Ordem do filtro, Suporte do filtro, Tempo de registro em segundos, Número de Canais) e sobre o arquivo de saída (Nome do arquivo, *Path* do arquivo, Nome do programa, Versão do Programa), etc.

CABEÇALHO 2 – contém os 48 valores dos parâmetros (Amplitude e Duração da Espícula, Desvio Médio de Amplitude no trecho, etc – referentes aos Modelos de Gotman) utilizados pelo sistema para a detecção de espículas e crises.

CABEÇALHO 3 – área com 256 *bytes* não-identificados/codificados.

NOMES DOS CANAIS – lista das derivações utilizadas.

SINAIS – os sinais de EEG correspondentes aos 24 ou 32 canais dos registros estão armazenados em uma matriz, da seguinte forma: cada linha da matriz contém o instante de início da varredura de amostragem dos canais, seguido por um valor ponto flutuante de amostra para cada um dos canais, alternados com espaços em branco (no caso dos arquivos em formato texto). O número de linhas da matriz depende do tempo de duração do registro.

### **Revisão dos Registros**

O próprio sistema Harmonie realiza marcações de detecção de espículas, ondas agudas e crises epiléticas nos registros. Estas marcações são armazenadas junto aos dados, em uma forma codificada.

Em seguida, duas revisoras do Montreal Neurological Institute fazem nova leitura dos sinais e acrescentam marcações onde o sistema não foi capaz de detectar os eventos epileptogênicos e eliminam algumas marcações errôneas realizadas pelo sistema.



No caso da base de sinais do SIDAPE, houve uma revisão adicional, realizada pela autora do trabalho e sob a supervisão do Dr. Jean Gotman, como parte do treinamento da mesma em leitura de EEGs, com vistas à marcação de espículas e ondas agudas.

A seleção das épocas, contendo eventos de interesse para treinamento e testes com o SIDAPE, foi realizada pela autora do trabalho, com posterior conferência por parte do Co-Orientador do trabalho, Prof. José Marino Neto, Professor Neurofisiologista da Universidade Federal de Santa Catarina.

### **Estrutura dos Arquivos utilizados no SIDAPE:**

Foram obtidos 9 arquivos de registro, provenientes de 7 pacientes comprovadamente epiléticos, para compor a base de dados do SIDAPE, tanto na versão texto quanto na binária.

Os 9 arquivos de texto foram lidos e apenas os dados referentes aos sinais (amostras e horários dos registros) foram organizados em matrizes, com 24 ou 32 linhas contendo 15 segundos de registro de cada canal e mais uma linha para armazenar os instantes de tempo para cada amostragem. Estas matrizes foram armazenadas em arquivos com formato binário do Matlab 5.0<sup>®</sup> (extensões \*.MAT).

E o seguinte conjunto de dados foi organizado:

- Paciente1 (“lap”) – 240 arquivos (*lap\_15.mat* a *lap\_3600.mat*), registrados no período de 00:29:59 a 01:29:59 h, do dia 30/05/1999, em 32 canais.
- Paciente2 (“wam”) – 240 arquivos (*wam\_15.mat* a *wam\_3600.mat*), registrados no período de 22:59:59 a 23:59:59 h, do dia 31/05/1999, em 32 canais.
- Paciente3 (“sr”) – 480 arquivos (*sr\_15.mat* a *sr\_7200.mat*), registrados no período de 14:59:59 a 16:59:59 h, do dia 01/06/1999, em 32 canais.
- Paciente3, 2º. registro (“sr2”) – 240 arquivos (*sr2\_15.mat* a *sr2\_3600.mat*), registrados no período de 22:32:59 a 23:32:59 h, do dia 02/06/1999, em 24 canais.
- Paciente4 (“vad1”) – 240 arquivos (*vad1\_15.mat* a *vad1\_3600.mat*), registrados no período de 22:59:59 a 23:59:59 h, do dia 03/06/1999, em 32 canais.
- Paciente4, 2º. registro (“vad2”) – 360 arquivos (*vad2\_15.mat* a *vad2\_5400.mat*), registrados no período de 02:59:59 a 04:29:59 h, do dia 05/06/1999, em 32 canais.
- Paciente5 (“zog”) – 360 arquivos (*zog\_15.mat* a *zog\_5400.mat*), registrados no período de 00:30:00 a 01:59:59 h, do dia 08/06/1999, em 32 canais.

- Paciente6 (“kur”) – 360 arquivos (*kur\_15.mat* a *kur\_5400.mat*), registrados no período de 13:29:59 a 14:59:59 h, do dia 09/06/1999, em 32 canais.
- Paciente7 (“jok”) – 360 arquivos (*jok\_15.mat* a *jok\_5400.mat*), registrados no período de 13:59:59 a 15:29:59 h, do dia 10/06/1999, em 32 canais.

Totalizando 2880 arquivos de EEG (240 registrados em 24 e 2640, em 32 canais) e com 15 segundos de duração, ou seja, o equivalente a 12 horas de registro.

Dentre estes 2880 arquivos, uma pré-seleção realizada pela autora do trabalho separou 359 (vide Seção 5.2), os quais continham eventos de interesse para implementação e treinamento do sistema SIDAPE. Os demais 2521 arquivos foram reservados para os testes com o sistema.

A figura da página seguinte mostra alguns destes arquivos, de 15 segundos de duração cada, com o objetivo de ilustrar a quantidade de espículas contidas nos registros.






Figura Anexo 1: Exemplos de arquivos da Base de Dados do SIDAPE, contendo espículas e ondas agudas.



## GLOSSÁRIO

**DESCARGA HIPERSINCRÔNICA** - gerada pela ocorrência de APDs (alterações paroxísticas despolarizantes) simultâneas em um grupo de neurônios, ocasionando uma atividade elétrica rítmica e de altas amplitudes.

**CRISE ELETROGRÁFICA** - atividade elétrica hipersincrônica no eletroencefalograma, com duração considerável e envolvendo vários canais, simultaneamente. Esta atividade geralmente tem morfologia de seqüências de espículas.

**CRISE ICTAL** - crise eletrográfica registrada durante a ocorrência de uma crise epiléptica clínica.

**CRISE INTERICTAL** - crise eletrográfica registrada entre ocorrências de crises epiléticas clínicas.

**ETIOLOGIA** - estudo das causas ou origens das patologias.

**ALCALOSE** - aumento do PH, das propriedades básicas do sangue devido à hiperventilação e conseqüente aumento da perda de ácido carbônico ( $\text{HCO}_3^-$ ) na expiração, com redução da concentração de íons de bicarbonato ( $\text{H}_2\text{CO}_3$ ) por compensação secundária nos rins.

**CRISES TÔNICAS** - crises epiléticas clínicas que se caracterizam pela manifestação física de aumento do tônus (enrijecimento) muscular esquelético involuntário.

**CRISES CLÔNICAS** - crises epiléticas que se caracterizam pela manifestação física de movimentos clônicos (série de contrações repetidas e involuntárias de um músculo esquelético ou de um grupo muscular).

**CRISES TÔNICO-CLÔNICAS** - crises epiléticas que se caracterizam pela manifestação clínica de aumento do tônus muscular e de movimentos clônicos.

**CRISE ATÔNICAS** - crises epiléticas clínicas que se caracterizam pela manifestação física de perda do tônus muscular involuntária.

**REGIÕES CEREBRAIS (FRONTAIS, TEMPORAIS, CENTRAIS, PARIETAIS, OCCIPITAIS)** – o córtex cerebral é dividido basicamente em 5 regiões, ou lobos (frontal, temporal, central, parietal e occipital) e em hemisférios, direito e esquerdo, conforme mostra a Figura Glossário 1.

**CRISES GENERALIZADAS** - crises eletrográficas cuja principal característica é iniciarem com envolvimento simultâneo de ambos hemisférios cerebrais.

**CRISES FOCAIS** - crises eletrográficas que se manifestam em uma área restrita do cérebro, pelo menos inicialmente, e têm propagação variável limitada e lenta no córtex cerebral. Entretanto, não raramente estas crises ficam circunscritas à área do córtex que as origina, gerando apenas sintomas focais como expressão epileptológica.




Figura Glossário 1: Superfície Cerebral e suas Regiões e Hemisférios

Algumas definições e conceitos aproveitados de [23]:

**FILTRAGEM DIGITAL:** processo de deixar passar algumas frequências, de um determinado sinal de entrada, e eliminar outras.

**SUBAMOSTRAGEM:** processo de manter apenas uma porção do vetor-sinal durante a computação - geralmente, desprezando uma amostra, a cada duas (subamostragem por 2). A subamostragem é uma operação fundamental no algoritmo rápido da pirâmide, para cálculo da transformada *wavelet*.

**ALGORITMO RÁPIDO:** implementação de um procedimento matemático (tal como a resolução de uma equação diferencial), que utilize significativamente muito menos cálculos do que seria nominalmente exigido, resultando tipicamente em uma aproximação.

**TRANSFORMADA DE FOURIER:** representação de um sinal ou imagem discretos como somatório de senóides complexas, que se estendem infinitamente no tempo.



**ALGORITMO DA PIRÂMIDE:** algoritmo rápido que é utilizada para computar a transformada *wavelet* e envolve uma série de operações de filtragem lineares combinadas com uma subamostragem por 2, da saída.

**CODIFICAÇÃO SUBBANDA:** um campo da engenharia intimamente relacionado a *wavelets* e voltado primariamente para aplicações de compressão de dados. O algoritmo rápido da pirâmide pode ser visto como um caso especial do algoritmo geral de codificação subbanda.

**ANÁLISE TEMPO-FREQÜÊNCIA:** decomposição do sinal em componentes com uma faixa de locações, durações e freqüências. A análise tempo-freqüência, a qual emprega pacotes *wavelet* e pacotes cosseno, é utilizada para visualizar-se como o comportamento das freqüências de um sinal variam com o tempo.

**SUPERAMOSTRAGEM:** reconstrução de um vetor de sinal a partir de dados comprimidos - geralmente através da duplicação dos dados a cada iteração, pela introdução de um valor entre dados adjacentes (superamostragem por 2). A superamostragem é uma operação fundamental no algoritmo rápido reverso da pirâmide, utilizado para reconstruir um sinal original a partir da transformada *wavelet*.

**WAVELET:** forma de onda oscilante que persiste por apenas um ou poucos ciclos. Uma dada *wavelet* tem uma locação (posição) e uma escala (duração). As *wavelets* são mais úteis para representação de sinais ou imagens com descontinuidades.

**PACOTE WAVELET:** forma de onda cujas oscilações persistem por diversos ou muitos ciclos, mas ainda são finitos. Um pacote *wavelet* tem uma locação (posição), uma escala (duração), e uma oscilação (freqüência). Os pacotes *wavelet*, uma classe de formas de onda tempo-freqüência, são úteis para a análise de dados com oscilações naturais, tais como sinais de fala e imagens de impressões digitais. Os pacotes *wavelet* são derivados de *wavelets* modificadas.

**TRANSFORMADA WAVELET:** representação de um sinal ou imagem discretos utilizando-se funções *wavelet* em diferentes locações e escalas, computadas com a utilização do algoritmo da pirâmide rápido.

**PROTOTIPAGEM:** prototipagem é o processo de desenvolvimento de uma versão em escala menor de um sistema, que será utilizado para a construção de um sistema em escala completa.



## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] AHO, A.; HOPCROFT, J.; ULLMAN, J. *Data Structures and Algorithms*. 1. ed. Massachusetts: Addison-Wesley Publishing Company, 1983.
- [2] AKAY, M. *Biomedical Signal Processing*. Academic Press: London, p. 375, 1994.
- [3] ALMEIDA, M. A. F. *Filtragem digital de sinais biomédicos*. Florianópolis, 1996. Dissertação (Mestrado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina.
- [4] ANDERSEN, P.; ANDERSSON, S. A. *Physiological Basis of the Alpha Rhythm*. New York: Meredith Corp., 1968.
- [5] APOLLONI, B. *et al.* Diagnosis of Epilepsy via Backpropagation. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (1990: Hillsdale). *Proceedings*. Hillsdale: Lawrence Erlbaum, 1990.
- [6] ARGOUD, F. I. M.; De AZEVEDO, F. M.; MARINO Neto, J.; BITTENCOURT, P. C. T. Estudo sobre bases Wavelet e Aplicação em Reconhecimento Automático de Espículas em Eletroencefalograma. In: CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA (17.: Set. 2000: Florianópolis). *Anais*. Vol. II, p: 1320-1324, ISBN: 85-7502-005-6.
- [7] ARGOUD, F. I. M.; De AZEVEDO, F. M.; MARINO Neto, J.; BITTENCOURT, P. C. T. Development of an Automatic System of Detection and Classification of Epileptiform Events in Electroencephalogram. In: EMBEC'99 - EUROPEAN MEDICAL & BIOLOGICAL ENGINEERING CONFERENCE (Nov. 1999: Vienna, Austria). *Proceedings*.
- [8] ARGOUD, F. I. M. *Detecção e Reconhecimento de Descargas Epileptiformes*, Florianópolis, 1998. Defesa de Qualificação para Doutorado em Engenharia Elétrica – Engenharia Biomédica, Centro Tecnológico, Universidade Federal de Santa Catarina.
- [9] ATTELIS, C. E.; ISAACSON, S. I.; SIRNE, R. O. Detection of epileptic

- events in electroencephalograms using wavelet analysis. *Annals of Biomedical Engineering*, v. 25, n. 1, p. 286-293, 1997.
- [10] BANKMAN, I. N. *et al.* Detection of the EEG K-complex wave with neural networks. In: ANNUAL IEEE SYMP. (4.) *Proceedings*. Washington D.C.: IEEE Computer Society Press, p. 280-287, 1991.
- [11] BARRETO, J. M. *Inteligência Artificial no limiar do Século XXI*. 2. ed. Florianópolis, 2000.
- [12] BARRETO, J. M. Redes neurais: aspectos matemáticos e computacionais. In: SOCIEDADE BRASILEIRA DE MATEMÁTICA APLICADA E COMPUTACIONAL - SBMAC96 (Ago. 1996, Universidade Federal do Maranhão). *Anais*. Florianópolis, p. 141.
- [13] BEAUCHAMP, K. G. *Transforms for Engineers*. 1. ed. Oxford, New York: Clarendon Press, 1987.
- [14] BERGER, H. Über das elektrenkephalogramm des menschen. *Arch. Psychiat. Nervenkr.* v. 87, n. 1, p. 527-570, 1929.
- [15] BERTEMES Fo., P. *Uma proposta de um sistema telemétrico para registro de potenciais bioelétricos*. Florianópolis, 1998. Dissertação (Mestrado em Engenharia Elétrica) - Engenharia Biomédica, Centro Tecnológico, Universidade Federal de Santa Catarina.
- [16] BIRAN, A.; BREINER; M. *MATLAB for Engineers*. 1. ed. Cambridge: Addison-Wesley, 1996.
- [17] BITTENCOURT, P. C. T. Tópicos controversos em epilepsia - quando tratar crises raras ou únicas. *Arq. Cat. Med.* v. 17, n. 2, p. 95-97, 1988.
- [18] BITTENCOURT, P. C. T. Decálogo para transformar o seu paciente com epilepsia em um doente mental. *Arq. Cat. Med.* v. 19, n. 4, p. 285-286, 1990.
- [19] BITTENCOURT, P. C. T. *et al.* Disritmia cerebral em um hospital universitário. *J. Bras. Psiq.* v. 42, n. 10, p. 541-545, 1993.
- [20] BOURGES-SÉVENIER, M. *Réalisation d'une bibliothèque C de fonctions ondelettes*. Relatório técnico 1, Rennes Cedex, France: IRISA - Institut de Recherche en Informatique et Systèmes Aléatoires, p. 108,

1994. e-mail:\*.bourges@irisa.fr - disponível na Internet em <http://www.wavelet.org/wavelet/digest—04/digest—04.01.html>.
- [21] BRASIL, L. M.; De AZEVEDO, F. M.; OJEDA, R. G.; BARRETO, J. M. A methodology for implementing hybrid expert systems. In: MELECON'96 - MEDITERRANEAN ELECTROTECHNICAL CONFERENCE (8.: May 1996: Bari, Italy). *Proceedings*. p. 661-664.
  - [22] BRASIL, L. M. *Aquisição de conhecimento aplicada ao diagnóstico de epilepsia*. Florianópolis, 1994. Dissertação (Mestrado em Engenharia Elétrica) - Engenharia Biomédica, Centro Tecnológico, Universidade Federal de Santa Catarina.
  - [23] BRUCE, A.; DONOHO, D.; GAO, H. Wavelet Analysis. *IEEE Spectrum*. p. 27-35, Oct. 1996.
  - [24] BUSSAB, W. O.; MORETTIN, P. A. *Estatística Básica – Métodos Quantitativos*. 4. ed. São Paulo: Atual Editora, 1987.
  - [25] CHAPA, J. O.; RAO, R. M. Optimal matched wavelet construction and its application to image pattern recognition. *Proc. SPIE - Wavelet Applications*, v. 2491, p. 518-529, 1995.
  - [26] CHAPA, J. O.; RAO, R. M. *Algorithms for Designing Wavelets to Match a Specified Signal*. Tech. Report. TR. CHAPARAO-98-1, Rochester, NY: Center of Imaging Science, RIT, Oct. 1998.
  - [27] CHENG, D. K. *Analysis of Linear Systems*. world student series ed. Massachusetts: Addison-Wesley, 1963.
  - [28] COIFMAN, R. R.; MEYER, Y. *Nouvelles bases orthonormées de  $L^2(\mathbb{R})$  ayant la structure du system de Walsh*. New Haven, CT: Dept. Mathematics, Yale University, Aug. 1989.
  - [29] COIFMAN, R. R.; MEYER, Y. *Orthonormal wave packet bases*. New Haven, CT : Dept. Mathematics, Yale University, Aug. 1990.
  - [30] COIMBRA, A. J. F. *Análise computadorizada de sinais bioelétricos*. Florianópolis, 1994. Dissertação (Mestrado em Engenharia Elétrica) - Engenharia Biomédica, Centro Tecnológico, Universidade Federal de Santa Catarina.



- [31] COIMBRA, A. J. F.; D'ANGELO, G. G.; De AZEVEDO, F. M.; MARINO Neto, J.; BARRETO, J. M. Electrographic analysis of brain states using neural networks. In: WORLD CONGRESS ON MEDICAL PHYSICS AND BIOMEDICAL ENGINEERING (Aug. 1994: Rio de Janeiro). *Proceedings*. p. Abstract PS17-1.11, 463.
- [32] COIMBRA, A. J. F.; MARINO Neto, J.; De AZEVEDO, F. M.; FREITAS, C. G.; BARRETO, J. M. Brain electrographic state detection using combined unsupervised and supervised neural networks. In: *Artificial Neural Nets and Genetic Algorithms*. Springer Verlag, 1995. p. 76-79.
- [33] COOPER, R. An ambiguity of bipolar recording. *Electroenceph. Clin. Neurophysiol.* v. 11, n. 1, p. 819, 1959.
- [34] COOPER, R.; OSSELTON, J. W.; SHAW, J. C. *EEG Technology*. 2. ed. London: Butterworth, 1974.
- [35] DARWIN, C. *The origin of species*. Danbury, Connecticut: Grolier Enterprises Corp., 1859.
- [36] DAVIS, G.; MALLAT, S.; ZHANG, Z. Adaptive time-frequency decomposition with matching pursuit. In: *Wavelets Theory, Algorithms and Applications*. Boston: Academic Press, 1994.
- [37] Da SILVA, F. L.; DIJK, A., SMITS, H. Detection of nonstationarities in EEGs using the autoregressive model. An application to the EEGs of epileptics. In: Dolce G, Künkel H, eds. *CEAN: Computerized EEG analysis*, Stuttgart: Fischer, 1975, p.180-199.
- [38] De AZEVEDO, F. M. *Contribution to the Study of Neural Networks in Dynamical Expert System*. Namur, Bélgica, 1993. Tese (Doutorado) - Institut d'Informatique, FUNDP.
- [39] De AZEVEDO, F. M. Uma proposta de modelos formais de neurônios e redes neurais artificiais. In: CONGRESSO BRASILEIRO DE REDES NEURAIS (3.: Jul. 1997: Florianópolis). *Anais*. p. 503-514.
- [40] DONOHO, D. L. *Interpolating wavelet transforms*. Pré-Impressão, 1992.

- [41] DORFFNER, G.; RAPPELSBERGER, P.; FLEXER, A. Using selforganizing feature maps to classify EEG coherence maps. In: ICANN '93 (1993: Heidelberg). *Proceedings*. p. 882-887. Heidelberg: Springer-Verlag, 1993.
- [42] DÜMPELMANN, M.; ELGER, C. E. Visual and Automatic Investigation of Epileptiform Spikes in Intracranial EEG Recordings. *Epilepsia*, v. 40, n. 3, pp.275-285, 1999.
- [43] DURKA, P. J.; BLINOWSKA, K. J. Analysis of EEG transients by means of Matching Pursuit. *Annals of Biomedical Engineering Society*, v. 23, n. 1, pp. 608-611, 1995.
- [44] ENGLEHART, K. *Signal Representation for Classification of the Transient Myoelectric Signal*. Fredericton, Canada, 1998. Thesis (Doctoral) – University of New Brunswick.
- [45] EPILEPSY TEACHING WEEKEND (4.: Sep. 1993: Oxford). *Lecture Notes*. Worcester College, Oxford: Ciba-Geigy Scientific Publications.
- [46] FRIEDMAN, E.; PAMPIGLIONE, G. Prognostic implications of electroencephalographic findings of hypsarrhythmia in first year of life. *Br. Med. J.* v. 4, n. 1, p. 323-325, 1971.
- [47] FROST Jr., J. D. Automatic recognition and characterization of epileptiform discharges in the human EEG. *J. Clin. Neurophysiol.* v. 2, n. 1, p. 231-249, 1985.
- [48] FUKUSHIMA, K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol. Cybernetics*. v. 36, n. 1, p. 193-202, 1980.
- [49] FUKUSHIMA, K.; MIYAKE, S. Neocognitron: A new algorithm for pattern recognition. *Pattern Recognition*. v. 15, n. 6, p. 455-469, 1982.
- [50] GABOR, A. J.; SEYAL, M. Automated interictal EEG spike detection using artificial networks. *Electroenceph. Clin. Neurophysiol.* v. 83, n. 1, p. 271-280, 1992.
- [51] GABOR, D. Theory of communication. *J. Inst. Elec. Eng.* v. 93, n. 1, p. 429-457, 1946.

- [52] GIBBS, F. A.; GIBBS, E. L. Atlas of electroencephalography. *Epilepsy*, v. 2, n. 1, 1952.
- [53] GLOOR, P. Hans Berger - psychophysiology and the discovery of the human electroencephalogram. In: *Epilepsy. HANS BERGER CENTENARY SYMPOSIUM* (1991: Edinburgh, London). *Proceedings*. p. 353-373. New York: Churchill Livingstone.
- [54] GOTMAN, J.; GLOOR, P. Automatic recognition and quantification of interictal epileptic activity in human scalp EEG. *Electroenceph. Clin. Neurophysiol.* v. 41, p. 513-529, 1976.
- [55] GOTMAN, J. Automatic recognition of epileptic seizures in the EEG. *Electroenceph. Clin. Neurophysiol.* v. 54, n. 1, p. 530-540, 1982.
- [56] GOTMAN, J. Automatic recognition of interictal spikes. *Electroenceph. Clin. Neurophysiol.* v. Suppl. 37, n. 1, p. 93-114, 1985.
- [57] GOTMAN, J., GLOOR, P.; SCHAUL, N. Comparison of traditional reading of the EEG and automatic recognition of interictal epileptic activity. *Electroenceph. Clin. Neurophysiol.* v. 44, n. 1, p. 48-60, 1978.
- [58] GOTMAN, J., IVES, J. R.; GLOOR, P. Automatic recognition of interictal epileptic activity in prolonged EEG recordings. *Electroenceph. Clin. Neurophysiol.* v. 46, n. 1, p. 510-520, 1979.
- [59] GOTMAN, J.; WANG, L. Y. State-dependent spike detection: concepts and preliminary results. *Electroenceph. Clin. Neurophysiol.* v. 79, n. 1, p. 11-19, 1991.
- [60] GRÖZINGER, M.; RÖSCHKE, J.; KLÖPPEL, B. Automatic recognition of rapid eye movement (rem) sleep by artificial neural networks. *J. Sleep Res. European Sleep Research Society.* v. 4, n. 1, p. 86-91, fev. 1995.
- [61] GUERREIRO, C. A. M. Epilepsias: Introdução. In: *Epilepsia*. 1. ed. São Paulo: Lemos, 1993. p. 11-18.
- [62] HAAR, A. *Apêndice*. 1910. Tese (Doutorado).
- [63] HAHN, S. L. Hilbert transform. In: *The Transforms and Applications Handbook*. 1. ed. Boca Raton, Flórida: CRC Press and IEEE Press, 1996. p. 463-629.



- [64] HARARY, F. *Graph Theory*. 1. ed. Massachusetts: Addison-Wesley Publishing Company, 1971.
- [65] HEBB, D. *Organization of Behavior*. 1. ed. New York: John Wiley & Sons, 1949.
- [66] HESS, R. *EEG Handbook*. 1. ed. London: Sandoz, 1966.
- [67] HILL, D.; PARR, G. *Electroencephalography*. 2. ed. London: Macdonald, 1963.
- [68] HOFFMANN, K. *et al.* Analysis and classification of interictal spikes discharges in Benign Partial Epilepsy of Childhood on the basis of the Hilbert transform. *Neuroscience Letters*. v. 211, n. 1, p. 195-198, 1996.
- [69] HOSTETLER, W.E.; DOLLER, H.J.; HOMAN, R.W. Assessment of a computer program to detect epileptiform spikes. *Electroenceph clin Neurophysiol*; v. 83. p. 1-11, 1992
- [70] ILAE - COMISSION ON CLASSIFICATION & TERMINOLOGY OF THE INTERNATIONAL LEAGUE AGAINST EPILEPSY. Proposal for revised clinical and electroencephalographic classification of epileptic seizures. *Epilepsia*. v. 22, n. 1, p. 489-501, 1981.
- [71] ILAE - COMISSION ON CLASSIFICATION & TERMINOLOGY OF THE INTERNATIONAL LEAGUE AGAINST EPILEPSY. Proposal for revised classification of epilepsies and epileptic seizures. *Epilepsia*. v. 30, n. 1, p. 389-399, 1989.
- [72] IVES, J. R.; MAINWARING, N. R.; SCHOMER, D. LO. Monitorização eletrencefalográfica (EEG). In: *Epilepsia*. 1. ed. São Paulo: Lemos, 1993. p. 39-46.
- [73] JACKSON, J. H. *Selected Writings of John Hughlings Jackson*. 1. ed. London: Hodder and Stoughton, 1931.
- [74] JANDÓ, J. *et al.* Pattern recognition of the electroencephalogram by artificial neural networks. *Electroenceph. Clin. Neurophysiol*. v. 86, n. 1, p. 100-109, 1993.
- [75] JOBERT, M. *et al.* Wavelet - a new tool in sleep biosignal analysis. *J. Sleep Res.* v. 3, n. 1, p. 223-232, 1994.

- [76] JUNG, T. P.; MAKEIG, S. Predicting failures in auditory detection from changes in the EEG spectrum. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (17.: 1995: U.S.A.). *Proceedings*.
- [77] KALAYCI, T.; ÖZDAMAR, O. Wavelet preprocessing for automated neural network detection of EEG spikes. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (Mar. 1995). *Proceedings*. p. 160-166.
- [78] KARTALOPOULOS, S. V. *Understanding Neural Networks and Fuzzy Logic Basic Concepts and Applications*. 1. ed. Piscataway, NJ: IEEE Press, 1996.
- [79] KILOH, I. C.; MCCOMAS, A. J.; OSSELTON, J. W. *Clinical Electroencephalography*. 3. ed. London: Butterworths, 1972.
- [80] KOHONEN, T. *Self-Organization and Associative Memory*. 1. ed. Berlin: Springer-Verlag, 1984.
- [81] KOHONEN, T. *Learning Vector Quantization*. Relatório técnico TKK-F-A601, Laboratory of Computer and Information Science, Helsinki University of Technology, Finland, 1986.
- [82] KOHONEN, T. The self-organizing map. In: *Neural Networks - Theoretical Foundations and Analysis*. 1. ed. Piscataway, NJ: IEEE Press, 1991. p. 74-90.
- [83] KOOI, K. A. *Fundamentals of Electroencephalography*. 1. ed. New York: Harper and Row, 1971.
- [84] KUFFLER, S. W.; NICHOLLS, J. G. The physiology of neuroglial cells. *Erg. Physiol.* v. 57, n. 1, p. 1-90, 1966.
- [85] LAIDLAW, J.; STANTON, J. B. *The EEG in Clinical Practice*. 1. ed. Edinburgh: Livingstone, 1966.
- [86] LAU, C. *Neural Networks - Theoretical Foundations and Analysis*. 1. ed. Piscataway, NJ: IEEE Press, 1991.
- [87] LENNOX, W. G.; DAVIS, J. P. Clinical correlates of the fast and the slow spike-wave electroencephalogram. *Trans. Am. Neurol. Ass.* v. 74, n.

- 1, p. 194-197, 1949.
- [88] LINS, S. G. *Epilepsia*. 19. ed. Recife: Universidade Federal de Pernambuco, 1983.
  - [89] LOPES, H. S.; NASSAR, S. M.; RAMIREZ, A.; De LIMA, W. C. Arquiteturas híbridas integrando paradigmas conexionistas e simbolistas. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (1.: Set. 1993: Rio Claro, SP). *Anais*. p. 10-18.
  - [90] LOUNSBERRY, M.; DEROSE, T. D.; WARREN, J. *Multiresolution surfaces of arbitrary topological type*. Versão atualizada, jan. 1994.
  - [91] MALLAT, S. G.; ZHANG, Z. Matching Pursuit with frequency dictionaries. *IEEE Trans. Sign. Proc.* v. 41, p. 3397-3415, 1993.
  - [92] MARTINET, R. K.; MORLET, J.; GROSSMANN, A. Analysis of sound patterns through wavelet transforms. *International J. of Pattern Recogn. and Artificial Intellig.* v. 1, n. 2, p. 273-302, 1987.
  - [93] MCCULLOCH, W. S.; PITTS, W. H. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysic* v. 1, n. 5, p. 115-133, 1943.
  - [94] MEYER, Y. *Wavelets: Algorithms and Applications*. Philadelphia, P.A.: SIAM, Translated and Revised by R. D. Ryan, 1993.
  - [95] MINSKY, M. L.; PAPERT, S. A. *Perceptrons: an introduction to computacional geometry*. Massachussets: The MIT Press, 1969.
  - [96] MIZRAHI, E. M. Avoiding the pitfalls of EEG interpretation in childhood Epilepsy. *Epilepsia - International League Against Epilepsy*. v. 37, n. 1, p. S41-S51, 1996.
  - [97] NIEDERMEYER, E.; Da SILVA, F. L. *Electroencephalography - Basic Principles, Clinical Applications, and Related Fields*. 3. ed. Maryland, EUA: Williams and Wilkins, 1993.
  - [98] O'DONOHUE, N. V. *Epilepsias na Infância*. 1. ed. São Paulo: Livraria Roca, 1982.
  - [99] OJEDA, R. G.; De LIMA, W. C.; DUARTE, D. F. Expert system for anesthesiology with neural networks. In: IASTED INTERNATIONAL



- CONFERENCE, EXPERT SYSTEMS & NEURAL NETWORKS (5.: Aug. 1989: Honolulu, Hawaii). *Proceedings*.
- [100] OJEDA, R. G.; De LIMA, W. C.; DUARTE, D. F. Expert system for evaluation and proposal of anesthetic procedures with neural networks. In: INTERNATIONAL CONFERENCE ON SYSTEMS ENGINEERING (Jul. 1990: Las Vegas, USA). *Proceedings*.
- [101] ÖZDAMAR, O.; YAYLALI, I.; JAYAKAR, P.; LOPEZ, C. N. Multilevel neural network system for EEG spike detection. In: ANNUAL IEEE SYMP. (4.: 1991: Washington D.C.). *Proceedings*. Washington D. C.: IEEE Computer Society Press, p. 272-279.
- [102] PASSOLD, F.; OLIVEIRA, J. P.; DIAS, J. S.; OJEDA, R. G.; De LIMA, W. C. Proposta e avaliação de procedimentos anestésicos para pacientes críticos/problemáticos através de sistema especialista híbrido. In: CONGRESO CHILENO DE INGENIERIA ELECTRICA (10.: Nov. 1993: Valdivia, Chile). *Anais*. p. I-43/48.
- [103] PENFIELD, W.; JASPER, H. *Epilepsy and the Functional Anatomy of the Human Brain*. 1. ed. Boston: Little, Brown and Company, 1954.
- [104] PORTER, R. J. *Epilepsia - 100 Princípios Básicos*. 1. ed. Rio de Janeiro: Interamericana, 1985.
- [105] POULARIKAS, A. D. Signals and systems. In: *The Transforms and Applications Handbook*. 1. ed. Boca Raton, Flórida: CRC Press and IEEE Press, 1996. p. 1-94.
- [106] PRADHAN, N.; SADASIVAN, P. K.; ARUNODAYA, G. R. Detection of seizure activity in EEG by an artificial neural network: a preliminary study. *Comput. Biomed. Res.* v. 29, n. 4, p. 303-313, 1996.
- [107] PRINCIPE, J. C.; GALA, S.; CHANG, T. Sleep staging automation based on the theory of evidence. *IEEE Trans. on Biom. Eng.* v. 36, n. 5, p. 503-518, maio 1989.
- [108] PURPURA, V. *et al.* *Physiological Basis of the Alpha Rhythm*. New York: Raven Press, 1972.
- [109] RAGAZZO, P. C. Eletrencefalografia nas epilepsias. In: *Epilepsia*. 1. ed. São Paulo: Lemos, 1993. p. 31-38.

- [110] RAO, R. M.; CHAPA, J. O.; Lt Col. Object Detection Through Matched Wavelet Transforms. *Proc. SPIE - Wavelet Applications III.*, v. 2762, p. 45-50, 1996.
- [111] RECHTSCHAFFEN, A.; KALES, A. *A manual of standardized terminology, technique and scoring system for sleep stages of human subjects*. Relatório técnico NIH 204, Public Health Service, Washington D.C., 1968.
- [112] REILLY, E. L. EEG recording and operation of the apparatus. In: *Electroencephalography - Basic Principles, Clinical Applications, and Related Fields*. 3. ed. Maryland, EUA: Williams and Wilkins, 1993. p. 104-124.
- [113] RIBEIRO, M. V. L. M.; SILVA, E. A. Convulsões neonatais. In: *Epilepsia*. 1. ed. São Paulo: Lemos, 1993. p. 47-52.
- [114] RODRIGUES, M. A. B. *Sistema para Detecção e Classificação Automática de Apnéias do Sono a partir de registros Polissonográficos*. Florianópolis, 1999. Defesa de Qualificação para Doutorado em Engenharia Elétrica – Engenharia Biomédica, Centro Tecnológico, Universidade Federal de Santa Catarina.
- [115] ROSE, A. L.; LOMBROSO, C. T. Neonatal seizure states. *Pediatric*. v. 45, n. 1, p. 404-425, 1970.
- [116] ROSEMBLATT, F. The Perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*. v. 65, n. 1, p. 386-408, 1958.
- [117] RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. In: *Parallel Data Processing*. 1. ed. Vol. 1, Chapter 8, Cambridge, MA: The M.I.T. Press, 1986. p. 318-362.
- [118] SANDER, J. W. A. S.; DUNCAN, J. S.; BITTENCOURT, P. C. T. O tratamento das crises epilépticas. *Arq. Cat. Med.* v. 15, n. 2/3, jun./set. 1986. p. 77-84,
- [119] SCHIFF, S. J.; ALDOUBRI, A.; UNSER, M.; SATAO, S. Fast Wavelet Transformations on EEG. *Eletroenceph. Clin. Neurophysiol.* v. 91,

- 1994, p. 442-455.
- [120] SCOTONI, A. E.; GUERREIRO, M. M. Epilepsias benignas da infância. In: *Epilepsia*. 1. ed.. São Paulo: Lemos, 1993. p. 53-58.
  - [121] SHENG, Y. Wavelet transform. In: *The Transforms and Applications Handbook*. 1. ed. Boca Raton, Flórida: CRC Press and IEEE Press, 1996. p. 747-827.
  - [122] SHERRIFF, S. B. *et al.* Use of principal component factor analysis in the detection of carotid artery disease from doppler ultrasound. *Med. & Biol. Eng. & Comput.* v. 20, n. 1, 1982. p. 351-356.
  - [123] SIGAKI, N.; De AZEVEDO, F. M.; BARRETO, J. M. Estudo do aprendizado baseado em casos em modelos de redes conexionistas IAC (interative activation and competition). In: CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA - FORUM NACIONAL DE CIÊNCIA E TECNOLOGIA EM SAÚDE (15.: Out. 1996: Campos do Jordão, SP). *Anais*. p. 725-726.
  - [124] SOMJEN, G. G.; TRACHTENBERG, M. Neuroglia as generator of extracellular current. In: *Origin of Cerebral Field Potentials*. 1. ed. Stuttgart: Thieme, 1979. p. 21-32.
  - [125] SPECHT, D. F. Probabilistic neural networks and the polynomial adaline as complimentary technique for classification. *IEEE Trans. Neural Networks*. v. 1, n. 1, p. 111-121, 1990.
  - [126] SPECHT, D. F. Probabilistic neural networks. *Neural Networks*. v. 3, p. 110-118, 1990.
  - [127] SPECHT, D. F. A General Regression Neural Network. *IEEE Trans. Neural Networks*. v. 2, p. 568-576, 1991.
  - [128] SPECKMANN, E. J.; ELGER, C. E. Introduction to the neurophysiological basis of the EEG and DC potentials. In: *Electroencephalography - Basic Principles, Clinical Applications, and Related Fields*. 3.ed. Maryland, EUA: Williams and Wilkins, 1993. p. 15-26.
  - [129] SPIEGEL, M. R. *Manual de Fórmulas e Tabelas Matemáticas. Coleção Schaum*. 1. ed. São Paulo: McGraw-Hill, 1974.



- [130] STELLE, A. L.; COMLEY, R. A. Portable analyser for real-time detection of the epileptic pre-cursor. *RBE*. v. 6, n. 2, p. 101-107, 1989.
- [131] STELLE, A. L.; COMLEY, R. A. The application of the Wigner distribution to the analysis of EEG signals. *RBE*. v. 7, n. 1, p. 670-676, 1990.
- [132] SWELDENS, W. *The lifting scheme: A construction of second generation wavelets*. Relatório técnico 1995:6, Industrial Mathematics Initiative, Department of Mathematics, University of South Carolina, 1995.
- [133] SWELDENS, W. The lifting scheme: A custom-design construction of biorthogonal wavelets. *Appl. Comput. Harmon. Anal.* v. 3, n. 2, p. 186-200, 1996.
- [134] SWELDENS, W.; SCHRÖDER, P. *Building Your Own Wavelets at Home - Introductory Material*. Disponível na Internet - home-page da The Wavelet Digest: <http://www.wavelet.org/wavelet/digest—04/digest—04.01.html>, 1997.
- [135] THAKOR, N. V.; SHERMAN, D. Wavelet (time-scale) analysis in biomedical signal processing. In: *The Biomedical Engineering Handbook*. 1. ed. Boca Raton, Flórida: CRC Press and IEEE Press, 1995. p. 887-906.
- [136] UNSER, M.; ALDOUBRI, A. A review of wavelets in biomedical applications. *Proc IEEE*. v. 84, p. 626-638, 1996.
- [137] WATERMAN, D. *et al.* Removal of ocular artifacts from the rem sleep EEG. *Sleep*. v. 15, n. 4, p. 371-375, 1992.
- [138] WEBBER, W. R. S. *et al.* Automated EEG spike detection: what should the computer imitate? *Electroenceph. Clin. Neurophysiol.* v. 87, n. 1, p. 364-373, 1993.
- [139] WEBBER, W. R. S. *et al.* Pratical detection of epileptiform discharges (EDs) in the EEG using an artificial neural network: a comparison of raw and parameterized EEG data. *Electroenceph. Clin. Neurophysiol.* v. 91, n. 1, p. 194-204, april 1994.

- [140] WICKERHAUSER, M. V. *Adapted Wavelet Analysis from Theory to Software*. 1. ed. New York: IEEE Press and A K Peters, 1994.
- [141] WIGNER, E. P. On the quantum correction for thermo-dynamic equilibrium. *Physics Review*. v. 40, n. 1, p. 749-759, 1932.
- [142] WILSON, N. F. *et al.* Electrocardiograms that represent the potential variations of a single electrode. *Am. Heart. J.* v. 9, n. 447, 1934.
- [143] WILSON, S.B.; HARNER, R.N.; DUFFY, F.H.; THARP, B.R.; NUWER, M.R.; SPERLING, M.R. Spike detection. I. Correlation and reliability of human experts. *Electroenceph clin Neurophysiol*; v. 98, p.186-198, 1996.
- [144] WISBECK, J. O. *Técnicas Híbridas de processamento de sinais biomédicos implementadas com redes neurais artificiais*. Florianópolis, 2001. Tese (Doutorado em Engenharia Elétrica) - Engenharia Biomédica, Centro Tecnológico, Universidade Federal de Santa Catarina.
- [145] WITTE, H. *et al.* Using discrete hilbert transformation to realize a general methodical basis for dynamic EEG mapping. a methodical investigation. *Automedic.* v. 13, n. 1, p. 1-13, 1990.
- [146] WITTE, H. *et al.* Use of discrete hilbert transformation for automatic spike mapping: a methodological investigation. *Med. & Biol. Eng. & Comput.* v. 29, n. 1, p. 242-248, 1991.
- [147] WITTE, H.; SAARINEN, J.; ROBERTS, S. *Spike detection in epilepsy*. 1995.
- [148] YACUBIAN, E. M. T. Epilepsia mioclônica juvenil. In: *Epilepsia*. 1. ed. São Paulo: Lemos, 1993. p. 65-72.
- [149] YAYLALI, I.; JAYAKAR, P.; ÖZDAMAR, O. Detection of epileptic spikes using artificial multilevel neural networks. *Electroenceph. Clin. Neurophysiol.* v. Suppl. 82, n. 1, 1992.